

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Samo Šela

**Fina lokalizacija grč z metodami
računalniškega vida**

DIPLOMSKO DELO
NA UNIVERZITETNEM ŠTUDIJU

MENTOR: doc. dr. Matej Kristan

Ljubljana, 2016

To delo je ponujeno pod licenco *Creative Commons Priznanje avtorstva-Deljenje pod enakimi pogoji 2.5 Slovenija* (ali novejšo različico). To pomeni, da se tako besedilo, slike, grafi in druge sestavine dela kot tudi rezultati diplomskega dela lahko prosto distribuirajo, reproducirajo, uporabljajo, priobčujejo javnosti in predelujejo, pod pogojem, da se jasno in vidno navede avtorja in naslov tega dela ter da se v primeru spremembe, preoblikovanja ali uporabe tega dela v svojem delu lahko predelava distribuira le pod licenco, ki je enaka tej. Podrobnosti licence so dostopne na spletni strani creativecommons.si ali na Inštitutu za intelektualno lastnino, Streliška 1, 1000 Ljubljana.



Izvorna koda diplomskega dela, njeni rezultati in v ta namen razvita programska oprema je ponujena pod licenco GNU General Public License, različica 3 (ali novejša). To pomeni, da se lahko prosto distribuira in/ali predeluje pod svojimi pogoji. Podrobnosti licence so dostopne na spletni strani <http://www.gnu.org/licenses/>.

Besedilo je oblikovano z urejevalnikom besedil \LaTeX .

IZJAVA O AVTORSTVU

diplomskega dela

Spodaj podpisani Samo Šela,

z vpisno številko 63010140,

sem avtor diplomskega dela z naslovom:

Fina lokalizacija grč z metodami računalniškega vida

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom doc. dr. Mateja Kristana,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) in ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela,
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, dne 26. 8. 2016

Podpis avtorja:

Najprej bi se rad zahvalil mentorju doc. dr. Mateju Kristanu za potrpežljivost, strokovne nasvete in smernice pri izdelavi diplomskega dela. Zahvala gre tudi prof. dr. Alešu Leonardisu in vsem ostalim članom Laboratorija za umetne vizualne spoznavne sisteme Fakultete za računalništvo in informatiko Univerze v Ljubljani, ki so me popeljali na zanimivo pot računalniškega vida.

Izvedba dela ne bi bila mogoča brez podpore podjetja Kolektor Orodjarna d. o. o., ki je omogočila pridobitev in uporabo podatkov. Posebej se zahvaljujem zaposlenim v oddelku PC Vision, ki so me pri delu vselej vzpodbujali.

Posebna zahvala gre mami in očetu za neizmerno potrpežljivost na tej dolgi izobraževalni poti. Hvala tudi Nini in hčerki Gaji, ki mi zmeraj pričarata lepši dan.

Samo Šela, 2016

Diplomsko delo posvečam babici in dedku.

Kazalo

Povzetek

Abstract

1	Uvod	1
1.1	Motivacija	1
1.2	Sorodna dela	11
1.3	Prispevki	12
1.4	Struktura	13
2	Teoretični okvir	15
2.1	Prehod iz analognega v digitalni svet	15
2.2	Teoretično ozadje segmentacije	17
2.3	Metoda Otsu	21
2.4	Učinkovita segmentacija slik na osnovi grafov	22
2.5	Segmentacija z razrezom grafa	24
3	Predlagana segmentacija in lokalizacija grče	37
3.1	Učenje modela mešanice Gaussovih porazdelitev	39
3.2	Algoritem Boykov-Kolmogorov	41
3.3	Algoritem za segmentacijo grč <i>Knotcut</i>	43
4	Eksperimentalna analiza	45
4.1	Sistem za zajem podatkov	45
4.2	Programsko orodje KiS	48

4.3	Zbirka slik grč	48
4.4	Mere zmogljivosti in postopek vrednotenja	53
4.5	Analiza metode Otsu	57
4.6	Analiza metode za učinkovito segmentacijo slik na osnovi grafov	65
4.7	Analiza predlagane metode	69
5	Sklepne ugotovitve	81
5.1	Nadaljnje delo	83
	Literatura	85

Povzetek

Naslov: Fina lokalizacija grč z metodami računalniškega vida

Cilj diplomskega dela je uspešno rešiti problem fine segmentacije grč in lesa. Tehnološka dovršenost v slovenski lesnopredelovalni industriji ni nekaj povsem samoumevnega, obstaja pa zavedanje, da je za konkurenčnost panoge nujno potreben napredek. Naše delo in prispevek se dotikata vpeljave strojnega vida v proces avtomatizacija pri proizvodnji opažnih plošč. Ozko grlo v procesu izdelave je namreč ročno krpanje prisotnih grč, ena izmed ključnih komponent avtomatizacije takšnega sistema pa je dobra lokalizacija grč. V delu smo širše orisali problem segmentacije. Predlagali in ovrednotili smo metodo segmentacije na podlagi iskanja najmanjšega prereza oziroma največjega pretoka v grafu. Metoda na podlagi grobo lokalizirane grče določi modela verjetnostne porazdelitve mešanice Gaussov za grčo in ozadje. Na podlagi pridobljenih modelov določimo območne in mejne uteži ter izgradimo graf, pri tem pa področje izven grobe regije grče upoštevamo kot seme in ga pripišemo ozadju. Izračun minimalnega prereza grafa je hkrati rešitev segmentacije. Rezultat sta dve ločeni regiji, kjer ena pripada grči, druga pa lesu. Vrednotenje predlagane metode smo predstavili na zbirki grč, pridobljeni pri enem izmed slovenskih proizvajalcev opažnih plošč med procesom izdelave. Za potrebo validacije metode smo zbirko 119 grč primerno anotirali in jo ponujamo kot javno dobro. Predlagana metoda je dosegla na celotni zbirki 99,00% točnost pri preciznosti 0,94 in priklicu 0,98.

Ključne besede: segmentacija, opažne plošče, grče, les, najmanjši prerez, največji pretok, najmanjši prerez v grafu.

Abstract

Title: Fine localization of wood knots using computer vision methods

The aim of this thesis is to find a viable solution for the fine segmentation of wood knots and lumber. Technological flawlessness is not inherent to the Slovenian wood processing industry and there is recognition that advancement is needed in order to ensure the industry's competitiveness. This work and contribution is concerned with the integration of computer vision in the automated process of manufacturing shuttering panels. The process of manually patching wood knots represents a bottleneck in the manufacturing process while the effective localization of wood knots is one of the key components in automating this type of system. This paper presents a broad outline of the problem of segmentation. Further, it proposes and evaluates a method of segmentation based on determining the minimum cut, or rather, the maximum flow, on a graph. Using a roughly localized wood knot as its basis, the model determines the probability distribution of the Gaussian mixture for the wood knot and background. Section and border weights are determined on the basis of the acquired models, a graph is constructed and the region outside of the rough section of the wood knot is considered as a base and worked into the background. Calculating the minimum cut of the graph simultaneously presents a solution for segmentation. The result are two separate regions, where one region belongs to the knot and the other to the wood. An evaluation of the proposed method was presented with a collection of wood knots obtained from a Slovenian manufacturer of shuttering panels during the manufacturing process. For the purpose of validating the

method, the collection of 119 wood knots was suitably annotated and made available as a public good. Over the entire collection, the proposed method achieved 99.00% accuracy for a precision of 0.94 and recall 0.98.

Keywords: segmentation, shuttering panels, knots, wood, minimum cut, maximum flow, graphcuts.

Poglavje 1

Uvod

1.1 Motivacija

1.1.1 Opredelitev problema

Potreba po tehnološki dovršenosti je pri zagotavljanju povečanja dodane vrednosti v lesnopredelovalni verigi ključnega pomena. To so pokazali Humar in sodelavci v delu [22], ki se navezuje na ciljni raziskovalni projekt V4-1010. Delo opisuje možnosti za prestrukturiranje slovenske lesne industrije za dvig dodane vrednosti izdelkom in dolgoročnim povečanjem števila zaposlenih ob rasti dodane vrednosti v panogi.


V poglavju Težave in izzivi slovenske lesne in pohištvene industrije se avtorji dotaknejo problema razvoja v lesnopredelovalnih podjetjih, kjer se v preteklih desetletjih ni namenjalo dovolj sredstev razvoju in razvojnim aktivnostim. Namesto razvoja so bili razvojni oddelki ukinjeni ali zelo okrnjeni. Posledice tega so bile med drugim vidne v tem, da ni bilo izrazitega in vidnega uvajanja novih, inovativnih, visokotehnoloških materialov in tehnologij. Prav tako se pozna pomanjkanje razvoja novih izdelkov z visoko dodano vrednostjo. Tehnološka opremljenost podjetij v proizvodni verigi je v posameznih elementih lesne industrije zastarela.

Država Slovenija je v tej panogi prepoznala velik potencial. To nakazuje

ustanovitev delovne skupine Gozd-les [41], ki sta jo skupaj ustanovila Ministrstvo za gospodarstvo in Ministrstvo za kmetijstvo, gozdarstvo in prehrano Republike Slovenije. Potencialne panoge pa so deležne razvojnih sredstev. Lesnopredelovalna industrija je bila tako opredeljena kot ena od prioriteta na razpisu "Javni razpis za pridobitev sredstev Evropskega sklada za regionalni razvoj – Razvojni centri slovenskega gospodarstva" [42]. V poglavju o viziji avtorji podajo podatek, da slovenska lesnopredelovalna industrija kot edina slovenska ekonomska panoga premore bogato surovinsko zaledje, geografsko ustrezno razpršene in tehnološko dokaj dobro opremljene predelovalne obrate ter močno razvejan trg za izdelke, ki jih čez polovico prodaja na tujih trgih. Vizija sledi predstavljenemu potencialu, da bi lahko ob prednostnem obravnavanju s strani države zopet postala ena izmed najpomembnejših gospodarskih panog v Sloveniji. Tako bi lahko do leta 2020 ponovno zaposlovala vsaj 20.000 ljudi. Med ključnimi cilji za uresničitev vizije so posodobitev tehnologij znotraj celotne gozdno-lesne proizvodnje verige z uporabo najboljših dostopnih tehnologij, povečanja proizvodnje in povečanje dodane vrednosti. Avtorji v študiji podajo predloge za prestrukturiranje, med katerimi je poudarek na tem, da mora lesnopredelovalna industrija preiti v industrijo znanja. Razvoj proizvodov mora spremljati prehod podjetij na stalno izboljševanje tehnološke in okoljske odličnosti. Tehnološko posodabljanje obratov bo omogočilo izdelavo sodobnih izdelkov z višjo dodano vrednostjo in hkratno obvladovanje okoljskih tehnologij. V lesnopredelovalni industriji je treba uvesti več avtomatizacije, robotizacije in informatizacije.

Diplomska naloga se osredotoča na problem natančne segmentacije grč in lesa v proizvodnji opažnih plošč. Fina lokalizacija je eden izmed ključnih in potrebnih pogojev za proces avtomatizacije proizvodnje. Opažne plošče spadajo med vezane lesne plošče, ki se uporabljajo predvsem v gradbeništvu. Gre za ravne, ploske polizdelke iz lesa. Prednost pri izdelavi lesnih plošč je možnost uporabe lesa slabše kakovosti, izkoristek pri predelavi lesa pa je tako boljši. Na ta način dosežemo dvoje: prvič, pocenimo končne izdelke,

Slika 1.1: Zgradba opažne plošče: natančna sestava iz treh navzkrižno zlepljenih slojev pod pravim kotom z obodnim okvirjem [20]. Surovina za proizvodnjo sta predvsem les smreke in jelke.



in drugač, povečamo dodano vrednost [3, str. 3]. Opažne plošče so izdelane tako, da je med seboj zlepljenih več slojev lesa. Posamezni sloji so zlepljeni križno (Slika 1.1). Med proizvodnim procesom izdelave take plošče je potrebno odpraviti napake v lesu. Da je odpravljanje napak v lesu najbolj časovno potratno opravilo, ugotavljajo Hofmair in sodelavci v delu [21], ki je del projekta, podprtega tudi z evropskimi sredstvi. V proizvodnem procesu še zmeraj povečini prevladuje ročno delo, ki ga bo potrebno zaradi silne konkurence kitajskih in indijskih dobaviteljev počasi opuščati. Eden izmed ključnih delov avtomatizirane proizvodne linije je lokalizacija in krpanje grč. Ročni postopek zahteva natančno pozicioniranje težke lesene plošče (npr. velikost 50 x 300 cm) pod stroj za povrtavanje in čepljenje s krpami vsake grče posebej. Nadomestitev človeka in njegove sposobnosti za lokalizacijo in klasifikacijo napak je sila težek problem. Na Sliki 1.2 lahko vidimo bogato raznolikost oblik in odtenkov grč ter lesa. Izbrana metoda mora kljub tej raznolikosti uspešno opraviti segmentacijo. Primer uspešne segmentacije lahko vidimo na Sliki 1.3.


1.1.2 Vizualno grupiranje in teorija Gestalt


Najprej želimo bralcu poljudno predstaviti in približati problematiko segmentacije, ki jo lahko orišemo z besedami grupiranje, percepcijsko grupiranje, percepcijska organizacija in prileganje [16, str. 433]. Iz mozaika 28 različnih primerov grč, prikazanih na Sliki 1.2, je mogoče videti, da je v nekaterih primerih grča svetlejšega odtenka kot v drugih primerih les, vendar nam to




Slika 1.2: Izbor različnih tipov grč. Podatke smo pridobili pri enem izmed slovenskih proizvajalcev opažnih plošč. Vidimo lahko raznolikost odtenkov in oblik, ki so prisotne v lesu.

Slika 1.3: Primer ločevanja grče in lesa (1.3a) Les z vraščeno grčo (1.3b) Maska, ki loči grčo od lesa (1.3c) Segmentiran les (1.3d) Segmentirana grča





Slika 1.4: 2D-optične iluzije [19, str. 65]




Slika 1.5: 3D-optične iluzije [16, str. 435]

ne zmoti razpoznavne. Tudi raznovrstnost oblik nam ne predstavlja prevelike ovire, da ne bi mogli z nekoliko truda dobro ločiti grče od lesa.

Kar je ljudem povsem samoumevno, predstavlja na področju računalniškega vida še nerešen problem. Gonzalez [19, str. 65] nam predstavi sposobnost človeške perceptualne organizacije na primeru dveh optičnih iluzij, ki ju prikazuje Slika 1.4. V prvi lahko zaznamo navidezno prisotnost kvadrata, v drugi pa kroga. Pretkana postavitve krožnih izsekov v prvem in premic v drugem primeru vzbudi v možganih odziv, ki s pomočjo znanih geometrijskih konceptov iz vsakdanjega življenja priključuje v človeške misli koncept kvadrata oziroma kroga. Soroden problem 3D nam predstavi Forsyth [16, str. 435]. Slika 1.5 prikazuje primer organizacije ali grupiranja velikih binarnih objektov na takšen način, da opazovalec dobi vtis teksturirane površine, ki navidezno spominja na kroglo.

Omenjeni primeri optičnih iluzij nas napeljujejo na misel ali vsaj poskušajo nakazati, da človek zmeraj gleda na stvari znotraj nekega širšega konteksta. S tem konceptom se formalno ukvarja šola psihologije *Gestalt*,




Slika 1.6: Dekompozicija na podobo in platno [16, str. 438]

ki ima svoje začetke konec osemnajstega in pričetek devetnajstega stoletja. Grupiranje je postavljeno v ospredje in je ključ do razumevanja vizualne zaznave. Teorija ima tudi svoje kritike, vendar nam tukaj služi le kot opora pri razumevanju in ne kot vsesplošen aksiom. Tipičen primer segmentacije slike je dekompozicija, kjer slika razpade na podobo, torej objekt ali stvar, ki jo opazujemo, ter platno, ozadje, na katerem opazovana podoba leži. Kaj je objekt in kaj platno, je stvar interpretacije. Primer prikazuje Slika 1.6, kjer se poraja vprašanje, ali gre za svetel objekt, ki leži na temni podlagi, ali za temen objekt s sredinsko izvrtino, ki leži na svetli podlagi.

V središču teorije *Gestalt* je beseda celota, okrog katere je spletena vrsta pravil, ki določajo, kako se slikovni elementi združujejo in tvorijo to celoto. Primere podajamo na Sliki 1.7.

- Bližina (angl., *proximity*): elemente, ki ležijo blizu drug drugega, dojemamo kot celoto.
- Podobnost (angl., *similarity*): elemente, ki so si med seboj podobni, dojemamo kot celoto. Podobnost je v tem kontekstu lahko na primer barva ali oblika elementov.
- Skupna usoda (angl., *common fate*): elementi, ki se navidezno premikajo z enakim vektorjem hitrosti, dojemamo kot zaključeno celoto.
- Skupna regija (angl., *common region*): elementi, ki so zaprti ali obdani z neko skupno mejo.
- Vzporednost (angl., *parallelism*): elemente, ki ležijo paralelno, dojemamo kot celoto.



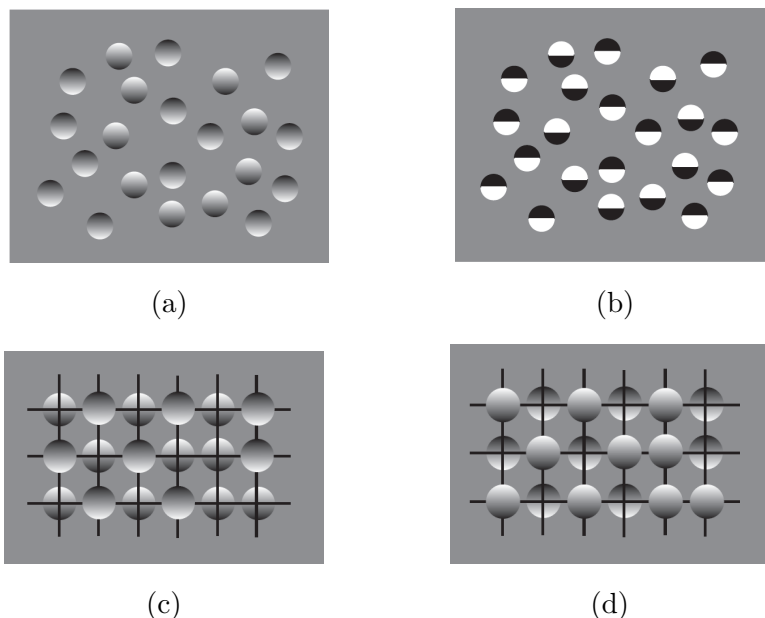
Slika 1.7: Nekaj primerov pravil *Gestalt* v praksi (1–1) Negrupirani elementi (1–2) Pravilo bližine (1–3) Pravilo podobnosti (1–4) Pravilo skupne regije (2–1) Pravilo zveznosti (2–2) Pravilo zaprtja (2–3) Pravilo vzporednosti (2–4) Pravilo simetrije

- Zaprtje (angl., *closure*): elementi, ki so po svoji naravi zaključeni, tvorijo celoto.
- Simetrija (angl., *symmetry*): elemente, ki so simetrično razporejeni okrog neke navidezne točke, dojemamo kot celoto.
- Zveznost (angl., *continuity*): elementi, ki si v subjektivnem človeškem pogledu lepo sledijo, tvorijo celoto.
- Poznana organiziranost (angl., *familiar configuration*): elementi, ki ob združitvi dajejo občutek percepcije znane podobe, tvorijo celoto.

Našteta pravila lahko obravnavamo kot smiselno razlago za dojetje človeške percepcije. Seveda to ne pomeni, da bo sklepanje v obratni smeri obrodilo sadove. Prav s tem problemom so se srečevali pripadniki šole *Gestalt*, saj je predstavljala definicija algoritmov, ki bi temeljili izključno na teh pravilih, nepremostljivo prepreko.

Kompleksnost človeškega vida in sposobnost percepcije bomo dodatno podkrepili s primerom evolucijske adaptacije na svetlobo, ki prihaja od sonca,

Slika 1.8: Primer sklepanja oblike in organizacije v prostoru glede na prisotnost različnega načina senčenja [11, str. 58 in 59]



ter težavami s poznim razvojem vida pri otrocih, ki so bili slepi od rojstva.

Chunharas in Ramachandran se v članku z angleškim naslovom *Out of the shadows*, kar v prevodu pomeni iz sence, v [11] poigrata s človeško adaptacijo na svetlobo, ki prihaja od sonca, ter posledično sencami in oblikami, ki jih ta svetloba ustvarja. Pri tem zapišeta nekaj pravil:

- če so stvari sicer enake, dajemo prednost konveksnosti,
- pravilo enega vira svetlobe,
- edini vir svetlobe sveti od zgoraj.

Podana pravila o pridobivanju oblike na podlagi senčenja nam pomagajo pri razumevanja primerov, ki jih lahko vidimo na Sliki 1.8. Slika 1.8a prikazuje primer, kako senčenje, ki je posledica vira svetlobe, ki prihaja od zgoraj, povzroči, da vidimo "krogle", medtem ko vir svetlobe, ki prihaja od spodaj,

daje vtis, da so prisotne "luknje". Seveda ne moremo trditi enako za primer na Sliki 1.8b. To nakazuje, da je senčenje in ne le variacija v intenziteti svetlobe, elementarni del razumevanja in dojemanja oblike.

Na primeru Slik 1.8c in 1.8d vidimo, kako senčenje podaja informacijo o prostoru. Medtem ko črte na drugi sliki lepo tečejo nad "luknjami" in pod "krogli", kar je skladno s splošnim dojetjem globine prostora, na prvi sliki to ne drži.

Pawan Sinha v [34] opiše svoje humanitarno raziskovalno delo, poimenovano Projekt Prakash. Beseda *prakash* v staroindoevropskem jeziku sanskrit pomeni svetloba. Zdravljenje slepih in slabovidnih otrok je nevroznanstveniku z univerze MIT odkrilo del sveta delovanja človeškega vida.

Med zdravljenjem otrok in mladostnikov, ki so po zdravljenju prvič ugleдали luč sveta, je ugotovil, da imajo težave s tvorjenjem delcev scene v smiselno celoto. Raziskovalni del projekta je tako podal dodatni uvid v vprašanje, kako lahko naši možgani iz zmešnjave barv, odtenkov in teksture naredijo smiselno celoto. Operativni posegi, ki so potencialno vračali vid, so odpirali vprašanja, ali je morda pomoč za razvoj otroških možganov in celotnega živčnega sistema za vid prišla prepozno.

Kar pojmuje kot človeški vid, ima za sabo dva pomembna koncepta:

- intramodalna organizacija – posamezni kosi slike sestavljajo celotne objekte ter
- intermodalna organizacija – interakcija med vidom in ostalimi čuti.

Otroci, ki jim je bila povrnjena sposobnost videnja, so v začetni fazi imeli težave pri povezovanju posameznih delov v smiselne celote. Na Sliki 1.9 lahko vidimo, kakšne težave so imeli pri povezovanju različno osvetljenih regij in barv v večje smiselne celote. Če je vprašanje kvadratov morda bolj filozofske narave, sta primera krave in žoge za zdravega razumnega človeka povsem nedvoumna. Za te otroke lahko rečemo, da implicitna uporaba t. i. pravil *Gestalt* ni bila v celoti prisotna.

Slika 1.9: Primer težav pri segmentaciji dvodimenzionalnih objektov. Preverjanje sposobnosti vida pri otrocih po operacijah, ki so jim povrnilo vid, je pokazalo na težave pri dojemanju celote, kot jo dojemajo ljudje, ki imajo normalen razvoj vida v otroštvu. [34, str. 52]



(a)



(b)



(c)

Hitrost, kako hitro so se otroci naučili uporabljati na novo pridobljeno sposobnost vida, je bila predvsem odvisna od starosti, pri kateri so dobili operacijo, ki jim dala sposobnost videnja. Naučiti se videti je lahko trajalo od nekaj tednov pa do več mesecev. Eden od ključnih trenutkov na tej poti je bila vpeljava koncepta gibanja predmeta. Veliko lažje in hitreje so se naučili, da nekaj spada skupaj, če so se opazovani predmeti gibali.

Rezultati zdravljenja in hkratnega eksperimentalnega dela so pokazali, da je neuroplastičnost še zmeraj prisotna, vendar je sposobnost doseganja ostrine vida in percepcija zdravega človeka nedosegljiva.

Da bi podkrepili težo problematike segmentacije grč, smo poizkušali prikazati širše področje človeškega vida s področja percepcijskega grupiranja. Kar je za zdravega človeka trivialno, pa vendar subjektivno opravilo, v svetu algoritmov deluje samo v zelo omejenih okoliščinah.

Za metodo smo izbrali segmentacijo na podlagi minimizacije energije v grafu. Na gručenje lahko gledamo kot na problem razreza grafa na kose. Vsak slikovni element povežemo z vozliščem v uteženem grafu, kjer so uteži med povezavami velike, če so si elementi podobni, in majhne, če so elementi med seboj različni. Graf razrežemo na dve disjunktni množici, kjer ena predstavlja

opazovani objekt, druga pa ozadje, od katerega objekt ločujemo. Takšne probleme lahko rešimo s pomočjo metod za izračun največjega pretoka oziroma najmanjšega prereza v grafu.

1.2 Sorodna dela

Področje segmentacije je že v preteklosti postreglo s širokim naborom različnih metod, vse do danes pa je ostalo zelo aktivno. Razloge lahko iščemo v tem da, vsaj po našem vedenju, ne obstaja splošen sistem, ki bi bil enakovreden sposobnostim človeškega vida.

Gonzalez in Woods v [19, 10. poglavje] podata osnovni pregled starejših metod. Znan predstavnik segmentacije na podlagi iskanja robov je Cannyjev detektor robov [10]. Odmik od preprostih metod upravljanja predstavlja metoda Otsu [30]. Beucher in Lantuéjoul v [4] predlagata metodo morfoloških razvodij. Predlog rešitve za preveliko segmentiranost podaja Meyer v [26].

Felzenszwalb s sodelavci v [15] predstavi metodo segmentacije slik na osnovi grafov. Metoda uvede kriterijsko funkcijo, ki zajema določeno zaznavno pomembne nelokalne značilnosti slike, hkrati pa je računsko učinkovita. S tega področja prav tako prihaja metoda normaliziranih prerezov [33], ki poizkuša na podlagi mer podobnosti ločiti regije slikovnih elementov, ki so si med seboj različne. S področja interaktivne segmentacije na podlagi prereza grafa prihajata deli [7] in [6]. Uspešna razširitev je metoda GrabCut, podana v delu [31].

Podali smo le nekaj metod segmentacije, bralec lahko zasledi celosten pregled področja v [43].

Funck in sodelavci v [17] pogledajo širše področje algoritmov segmentacije za iskanje napak v lesu. Njihove ugotovitve so, da je za področje segmentacije slika lesa velik izziv. Izbira pravega algoritma je težka in zahteva fino prilagajanje parametrov glede na analiziran tip lesa. Največji potencial najdejo v metodah širjenja regije, posebej izpostavijo metodo Amadsuna in Kinga [2], ki združuje gručenje s širjenjem regij.

Lokalizacija je tipično samo vmesna stopnja v sistemih zaznavanja napak v lesu. Mohan in Venkatachalapathy se v delu [29] dotakneta problema ročnega odstranjevanja grč za povišanje kvalitete lesa in posledično doseganje višje cene končnega izdelka. Ovrednotita klasifikacijo različnih tipov grč na podlagi različnih pristopov metode *bagging*. Ovrednotene metode ne presežejo 81% klasifikacijske točnosti na zbirki 400 grč. Gu in sodelavci v [40] predlagajo drevesno strukturo metode podpornih vektorjev za klasifikacijo štirih tipov grč. Metoda dosega 96,5% povprečno klasifikacijsko točnost na zbirki 400 grč. Predlagana metoda se zanaša na fino lokalizacijo grče na podlagi detekcije robov. Ena izmed ključnih komponent uspešne klasifikacije določenih tipov grč je razlikovanje v barvi med grčo ter mejo, ki ločuje grčo in les.

1.3 Prispevki

Prispevki našega dela so naslednji. Osvetlili smo širši problem stanja tehnološke dovršenosti v slovenski lesnopredelovalni industriji. Pokazali smo pomembnost panoge za slovensko gospodarstvo in posluh države Slovenije za zagotavljanje potrebnih razvojnih sredstev.

V okviru sodelovanja pri procesu avtomatizacije lesne proizvodnje pri enem izmed slovenskih proizvajalcev smo zaznali težave pri procesu krpanja opaznih plošč, zato smo predlagali metodo za izboljšanje fine lokalizacije grč.

Za potrebe razvoja in vrednotenja predlagane metode smo ustvarili anotirano zbirko grč, ki jo predajamo v javno dobro. Tekom procesa zbiranja podatkov smo sodelovali predvsem s tehnologiji v proizvodnji in naleteli na veliko prepreko pri sporočanju razlage problema. V delu smo zato namenili poseben poudarek razumevanju koncepta in kompleksnosti problema segmentacije.

1.4 Struktura

Preostanek diplomskega dela je organiziran v štiri poglavja. V Poglavlju 2 si bomo naprej ogledali, kako ustvarimo digitalno sliko, in nato podali teoretično podlago segmentacije ter uporabljenih metod. V Poglavlju 3 bomo podrobno opisali predlagano metodo za fino lokalizacijo grč. Sledi Poglavlje 4, kjer bomo najprej opisali avtomatizirane sisteme za iskanje napak v lesu. Predstavili bomo programsko orodje KiS in sistem, s katerim smo pridobili našo zbirko. Opisali bomo pridobljeno zbirko grč, podali mere in postopke vrednotenja ter predstavili dobljene rezultate. Delo bomo zaključili s sklepno mislijo v Poglavlju 5. Povzeli bomo opravljeno delo, se kritično dotaknili spregledanih pomanjkljivosti in podali možne iztočnice za nadaljnje delo.

Poglavje 2

Teoretični okvir


2.1 Prehod iz analognega v digitalni svet

Sliko sveta spravimo v digitalno obliko s pomočjo digitalnega senzorja kamere (Slika 2.1). V nekaj naslednjih vrsticah bomo bralcu na grobo predstavili ta proces, pri tem pa zavestno zanemarili vse podrobnosti, ki presegajo obseg tega dela.

Opazovani objekt je osvetljen s svetlobnim virom, ki je lahko naravni ali umetni. Svetloba, ki obsije objekt, se od njega hkrati odbije. Del odboja, ki je usmerjen proti sistemu za zajem slike, se s pomočjo leče zbere na svetlobnem senzorju (Slika 2.2).


Svetlobni senzor je digitalno vezje, sestavljeno iz fotodetektorjev, ki fotone pretvarja v elektrone, ti pa se zbirajo v obliki električnega naboja. Ta se s pomočjo pretvornika spremeni v napetost. Napetost je dodatno ojačena in preko analogno-digitalnega pretvornika preslikana v digitalno numerično vrednost, ki ji pravimo intenziteta. Količina naboja in posledično intenzitete je neposredno odvisna od časa odprtosti zaslonke.

Pozoren bralec je ugotovil, da smo s tem opisali zajem sivinske slike. Način, kako dobimo barvno sliko, je odvisen od tipa kamere. V najpreprostejših modelih je nad senzorjem filter, ki na posamezne elemente prepušča različne valovne dolžine (npr. Bayerjev vzorec). V kompleksnejših modelih pa imamo




Slika 2.1: Primer preprostega sistema za zajem digitalne slike. (1) Vir svetlobe. (2) Opazovani objekt. (3) Sistem za zajem slike, npr. digitalna kamera s svetlobnim senzorjem CCD ali CMOS. (4) Projekcija opazovanega objekta na slikovno ravnino. (5) Digitalizirana slika objekta. [19, str. 51]

Slika 2.2: Osnove optike: optični sistem, sestavljen iz leče, zaslonke in drugih elementov, ki zagotavljajo, da se žarki zberejo v eni sami točki slike [37, str. 18–22].



Slika 2.3: Razlika med delovanjem barvnih kamer z enim ali tremi svetlobnimi senzorji [35, str. 42–45].



- (a) V kamerah s samo enim senzorjem je za zajem barvne slike potreben poseben filter, ki določa, katera valovna dolžina lahko obsije posamezni fotodetektor (npr. Bayerjev vzorec).
- (b) Barvna kamera s tremi senzorji. Svetloba se skozi prizmo razdeli tako, da obsije vse tri senzorje. Filtri določajo, katero valovno dolžino bo posamezni senzor zaznaval.




tri senzorje s filtri in prizmo, ki žarke usmeri nanje (Slika 2.3). Podrobnosti o delovanju senzorjev tipa CCD in CMOS lahko bralec najde v delu [35, str. 35–42].

2.2 Teoretično ozadje segmentacije

Najpreprostejši način segmentacije je uporaba fiksne pragovne vrednosti (angl., *threshold*), ki določa, kateremu razredu pripada posamezni slikovni element. Proces izvedemo v prostorski domeni slike [19, str. 105]. Barvne slike so sestavljene iz slikovnih elementov s tremi komponentami, ki so odvisne od barvnega prostora, v katerem so predstavljene. Za osnovo bomo vzeli temeljni barvni prostor, ki je najbližje človeškemu vidu. Tega v našem primeru tvorijo osnovne komponente rdeče, zelene in modre barve. Primer strukture barvne slike prikazuje Slika 2.4.

Sliko lahko predstavimo tudi s pomočjo histograma. Po definiciji je histogram digitalne slike z intenzitetnimi nivoji na intervalu $[0, L - 1]$ diskretna funkcija $h(r_k) = n_k$, kjer je r_k k-ta intenzitetna vrednost in n_k število slikov-

Slika 2.4: Predstavitev barvne slike v digitalni obliki



(a) Rezultat zajema objekta z barvno kamero je slika s tremi barvnimi komponentami.

(b) Primer manjšega izseka slike grče, kjer so vidni posamezni slikovni elementi.

62	63	65	70	76
64	67	75	86	98
105	115	122	133	140
63	61	62	65	71
64	64	70	76	87
112	100	112	116	134
62	62	61	62	69
66	66	67	74	85
105	107	112	122	132
68	68	62	62	68
67	65	69	75	84
100	104	112	121	131
68	61	62	62	66
66	69	72	78	85
105	106	112	119	128


105	115	122	133	140
102	108	112	125	134
103	109	112	122	132
100	104	112	121	131
103	106	112	119	128

64	67	75	86	98
64	64	70	76	87
66	66	67	74	85
67	65	69	75	84
66	69	72	78	85

62	63	65	70	76
63	63	62	65	71
62	62	61	62	69
66	66	62	62	68
66	61	62	62	66

(c) Od leve proti desni si sledijo najprej barvna slika, nato pa slike posamezne barvne komponente, rdeča, zelena in modra. Vsak slikovni element barvne slike vsebuje tri numerične vrednosti, ki predstavljajo različne nivoje intenzitete: $I(x, y) = (r, g, b); r, g, b \in \mathbb{N}; 0 \leq r, g, b \leq 255$.

Slika 2.5: Primer porazdeljenosti slikovnih elementov za Sliko 1.3



(a) Histogram slike

(b) Histogram grče

(c) Histogram lesa

nih elementov v sliki z intenziteto r_k . Normaliziran histogram dobimo tako, da posamezno komponento delimo s skupnim številom vseh slikovnih elementov. Takšna predstavitev je približek oziroma ocena verjetnostne porazdelitve pojavitve intenzitete nivoja r_k v sliki. Vsota vseh komponent porazdelitve oziroma normaliziranega histograma je enaka ena [19, str. 120]. Na Sliki 2.5 si lahko ogledamo primer prikaza histograma za sliko grče, podane v uvodnem poglavju.


Če pogledamo posamezno barvno komponento histograma na Sliki 2.5, opazimo, da grča predstavlja temnejše področje, medtem ko je les viden kot svetlejše področje. Da bi lahko ločili grčo od lesa, je potrebno v histogramu poiskati takšno vrednost pragovne intenzitete T , ki bo razreda ločila. Po definiciji prag določa, da slikovni elementi, za katere velja $I(x, y) > T$, pripadajo objektu, sicer so slikovni elementi del ozadja. Segmentirano sliko tako podaja enačba

$$I_b(x, y) = \begin{cases} 1 & I(x, y) > T \\ 0 & I(x, y) \leq T \end{cases}, \quad (2.1)$$

kjer je $I(x, y)$ vhodna slika; $I_b(x, y)$ je izhodna binarna slika, dobljena na podlagi praga T [19, str. 738]. Seveda pri tem ni težko videti, da lahko definicijo objekta in ozadja obrnemo. Kot praktični primer podajmo upravljanje Slike 1.3, rezultati so vidni na Sliki 2.6.

Pravkar uporabljena metoda se imenuje globalno upravljanje, saj uporablja enotno vrednost T za celotno sliko (v našem primeru smo enako vre-

Slika 2.6: Primer binarizacije za Sliko 1.3. (2.6a) Barvno sliko razbijemo na posamezne kanale (od leve proti desni si sledijo rdeč, zelen in moder), ki jih nato obravnavamo ločeno. Rezultat posameznih binarnih slik združimo v skupno sliko s pomočjo bitne operacije *in*. V vseh primerih smo uporabili enotno pragovno vrednost ne glede na kanal. (2.6b), (2.6c), (2.6d) Rezultat binarizacije pri različnih vrednostih T glede na posamezni kanal ter uporaba binarne maske za ločitev grče od preostalega lesa. Izbira tipa bitne operacije v povezavi z vplivom rdečega kanala je imela odločilen vpliv na končno segmentacijo.



(a) Barvna dekompozicija

(b) Prag T pri 90(c) Prag T pri 110(d) Prag T pri 130

dnost uporabili posebej za vsak kanal). Ob pogledu na histograme na Sliki 2.5a lahko opazimo, da je porazdelitev bimodalna. Odgovor, kako poiskati najboljšo pragovno vrednost T za bimodalne normalne porazdelitve, bomo podali v nadaljevanju.

2.3 Metoda Otsu

Na vprašanje, kako izbrati najboljšo pragovno vrednost T za bimodalne normalne porazdelitve, ima odgovor metoda Otsu za iskanje globalnega optima, poimenovana po svojem avtorju [19, str. 742–747]. Metoda Otsu loči sliko na dve gruči slikovnih elementov ob predpostavki, da je porazdelitev bimodalna tako, da minimizira varianco vrednosti slikovnih elementov znotraj gruče in maksimizira varianco vrednosti slikovnih elementov med gručama. To naredi ob pregledu vseh možnih izborov T . Druga nezanemarljiva lastnost te metode je učinkovita praktična implementacija, ki deluje nad histogramom slike. Podrobnosti o metodi si lahko bralec prebere v [19, str. 742–747].

Segmentacija na podlagi upravljanja bo neposredno odvisna od oblike histogramске porazdelitve [19, str. 739]. Vpliv izhaja neposredno iz:

1. ločitev vrhov v histogramu (bolj kot sta vrha narazen, lažje bomo izbrali prag med razredoma),
2. količina šuma v sliki (več šuma pomeni večje prekrivanje med razredoma),
3. relativna velikost objekta glede na ozadje,
4. enakomerna svetilnost vira,
5. enakomerne odbojne lastnosti scene.

Slika 2.7: Primer delovanja metode na sintetično generirani sliki [15, str. 4]. (a) Sintetično generirana slika, nad katero je izvedena segmentacija. (b) Rezultati metode za parametre: Γ_σ – predprocesiranje slike z glajenjem pred segmentacijo, Γ_κ – parameter za kriterijsko funkcijo. Parameter Γ_{siz} določa najmanjšo velikost regije v fazi postprocesiranja.



(a) Sintetična slika

(b) $\Gamma_\sigma = 0.8$, $\Gamma_\kappa = 300$

2.4 Učinkovita segmentacija slik na osnovi grafov

Odmik od navadnega upravljanja, bodisi globalnega, variabilnega bodisi optimalnega, predstavlja delo Felzenszwalba in sodelavcev z naslovom *Efficient Graph-Based Image Segmentation* [15], kar v prevodu pomeni učinkovita segmentacija slik na osnovi grafov. Delo podaja predikat, ki meri pojavnost meje med regijami na podlagi slike, predstavljene v obliki grafa. Vodilo pri razvoju splošne metode je bilo, da mora metoda, prvič, zajeti zaznavno pomembne skupine ali regije, ki pogosto odražajo globalni smisel slike, in drugič, biti izredno učinkovita. To pomeni, da se mora čas izvajanja približati linearni odvisnosti glede na število slikovnih elementov slike.

Metoda tako zajema določene zaznavno pomembne nelokalne značilnosti slike, hkrati pa je računsko učinkovita $O(n \log n)$. Metoda temelji na izbiri povezav v grafu, kjer vsak slikovni element pripada posameznemu vozlišču. Glede na izbrano sosednost so nekatera vozlišča povezana z neusmerjenimi povezavami. Uteži na vsaki povezavi določajo mero podobnosti med posameznimi slikovnimi elementi. Metoda adaptivno prilagaja kriterij segmentacije glede na stopnjo spremenljivosti v sosednjih regijah v sliki.

Avtorji podajo primer segmentacije računalniško ustvarjene slike, na katerem pokažejo, kako metoda ujame nelokalne značilnosti slike (Slika 2.7). Ljudje v splošnem dojamejo primera na Sliki 2.7a tako, kot da imamo tri pomensko različna območja: na levi polovici je prelivajoče se pravokotno področje, na desni polovici je področje z uniformno sivinsko vrednostjo, ki pa vsebuje tretje, manjše področje z močno spremenljivimi sivinskimi vrednostmi. Ta primer po njihovem mnenju predstavlja nekaj zaznavno pomembnih lastnosti, ki bi jih metoda segmentacije morala zajemati:

1. Močno spreminjajoče se vrednosti intenzitete same po sebi niso zadostni dokaz za obstoj večjega števila regij. Prav tako ni dovolj predvidevanje, da imajo regije skoraj konstante ali počasi spreminjajoče se intenzitete.
2. Zaznavno pomembni vidik je, da regij ne moremo dobiti samo na podlagi lokalnih odločitvenih kriterijev. Za doseg cilja potrebujemo nekakšen adaptivni ali nelokalni kriterij.

Razvita metoda meri pojavnost meje med regijama tako, da primerja dve veličini:

1. razlika v intenzitetah na meji med dvema regijama,
2. razlika v intenzitetah med sosednjimi slikovnimi elementi znotraj posamezne regije.

Intuitivno to pomeni, da je razlika v intenziteti na meji med dvema regijama zaznavno pomembna, če je ta relativno velika glede na razliko v intenziteti znotraj vsaj ene izmed regij. Podrobnosti metode lahko bralec poišče v delu [15]. Metoda definira sledeče parametre [15, str. 14–15]:

- Γ_σ – predprocesiranje slike z glajenjem pred segmentacijo,
- Γ_κ – parameter za kriterijsko funkcijo, ki dejansko določa obseg opazovanja, s tem da večje vrednosti dajejo prednost večjim komponentam,

- Γ_{siz} – najmanjša velikost segmenta v slikovnih elementih, upoštevana v fazi po segmentaciji. Metoda sprejme še tretji parameter, ki se uporablja v fazi postprocesiranja za združevanje regij.


2.5 Segmentacija z razrezom grafa

2.5.1 Prerez grafa

V našem delu se bomo osredotočili na metodo segmentacije, ki deluje na prevedbi problema ločevanja podobe in ozadja na problem izračuna maksimalnega pretoka v omrežju. Pravimo, da se problem A prevede na problem B , če lahko uporabimo algoritem, ki reši problem B , za izdelavo algoritma, ki rešuje problem A [32, str. 903].

Najprej podajmo osnovno terminologijo in definicijo grafa, ki nam bo v oporo pri razlagi problema [16, str. 452–454], [32, 4. poglavje].

- Graf $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ je množica vozlišč \mathcal{V} ter množica povezav \mathcal{E} , ki povezujejo posamezna vozlišča med sabo. Vsako povezavo lahko predstavimo s parom vozlišč $\mathcal{E} \subset \mathcal{V} \times \mathcal{V}$.
- Usmerjen graf vsebuje povezave oblike $v_i \rightarrow v_j$, kjer razlikujemo med povezavo (v_i, v_j) in (v_j, v_i) (desni graf na Sliki 2.8).
- Neusmerjen graf ne razlikuje med usmerjenostjo povezav $(v_i, v_j) \equiv (v_j, v_i)$ (levi graf na Sliki 2.8).
- Utežen graf pripiše vsaki povezavi še utež w_{ij} .
- Pot v grafu je zaporedje povezanih vozlišč, ki vodijo od (v_i) do (v_j) .
- Cikel je pot, kjer sta prvo in zadnje vozlišče enaki $(v_i) \equiv (v_j)$.
- Poljubni vozlišči v_i, v_j v grafu sta med seboj povezani, če obstaja pot med v_i in v_j .
- V povezanem grafu obstaja pot med vsakim parom vozlišč $(v_i), (v_j)$.




Slika 2.8: Primer neusmerjenega in usmerjenega grafa

V uteženem grafu, kakršnega bomo uporabili v našem primeru, je potrebno določiti uteži na povezavah. Vodilo, ki bo postalo jasno pri razlagi metode za izračun največjega pretoka v grafu, je velika utež za sorodna vozlišča ter majhna utež za različna vozlišča. Obstajajo različne mere podobnosti, s pomočjo katerih lahko te uteži določimo, odvisne pa so od problema, ki ga rešujemo. Merimo lahko na primer evklidsko razdaljo svetlobnih elementov, razliko v intenziteti svetlobnih elementov, razliko v barvi svetlobnih elementov in razliko v teksturi v okolici svetlobnih elementov [16, str. 454–457].

Sedgewick [32, str. 886] prične razlago izračuna največjega pretoka na primeru naftnega omrežja z enim izvorom (npr. naftno polje) in enim ponorom (npr. rafinerija). Primer takšnega omrežja prikazuje Slika 2.9. Pretok med izvorom in ponorom urejajo notranja vozlišča (v_1, v_2, v_3, v_4) in usmerjene povezave s točno določeno kapaciteto med temi vozlišči. Za vsako vozlišče velja ravnovesje vhodnih in izhodnih tokov. Povedano drugače, tok, ki prihaja v vozlišče, je enak toku, ki vozlišče zapušča. Naša naloga je ugotoviti največji pretok med izvorom in ponorom. Sedaj podajmo naš problem še v formalni obliki.

Pretočno omrežje je usmerjen, utežen graf s pozitivnimi cenami na povezavah (kapacitete); st-pretočno omrežje vsebuje dve posebej označeni vozlišči, izvor s in ponor t . Vozlišče s povezave samo zapuščajo, medtem ko v vozlišče t povezave samo vodijo. Povedano drugače, nobena povezava ne zapušča vozlišča t , hkrati pa nobena povezava ne vodi v vozlišče s . Definirajmo nekaj posebnih veličin:



Slika 2.9: Primer usmerjenega grafa, kjer smo povezavam pripisali kapacitete. Vozlišče v_0 predstavlja izvor. Vozlišče v_5 predstavlja ponor. Tok v tem grafu razumljivo teče od izvora proti ponoru.

- vhodni tok je vsota vseh tokov, ki prihajajo v vozlišče,
- izhodni tok je vsota vseh tokov, ki vozlišče zapuščajo;
- neto tok je razlika med vsoto vhodnih in vsoto izhodnih tokov v nekem vozlišču (Slika 2.10).


Funkcija tok $f(e)$ določa količino pretoka po povezavi e , funkcija $c(e)$ določa kapaciteto povezave e . Za st-pretok v grafu $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ velja:

- $f(e) \leq c(e)$,
- $f(e) \geq 0$,
- $\forall v \in \mathcal{V} \setminus \{s, t\}$:


$$\sum_{(u,v) \in \mathcal{E}} f((u,v)) = \sum_{(v,u) \in \mathcal{E}} f((v,u)) \Rightarrow f_{\text{neto}}(v) = 0.$$

Največji st-pretok. Za podano st-pretočno omrežje obstaja tak st-pretok, da nobeden drugi pretok iz izvora s v ponor t nima večje vrednosti. V angleščini iskanju največjega pretoka v omrežju pravimo *maximum flow* oziroma krajše kar *maxflow* [32, str. 888].

V nadaljevanju podajmo še drugo plat te medalje, definirajmo problem najmanjšega prereza v grafu. Prerez grafa je delitev množice vozlišč na dve



Slika 2.10: Prikaz vhodnih in izhodnih povezav s pripadajočimi tokovi. Za vozlišče v_i velja, da je razlika vsote vseh vhodnih tokov in vsote vseh izhodnih tokov enaka nič.



Slika 2.11: Skica st-prereza v grafu \mathcal{G} . Prerez \mathcal{C} tvorijo povezave e_1, \dots, e_5 ; pri tem velja, da je izvor $s \in \mathcal{U}$ ter ponor $t \in \mathcal{V} \setminus \mathcal{U}$. Kapaciteta prereza je $\sum_{e \in \mathcal{C}} c(e)$.

disjunktni množici \mathcal{U} in $\mathcal{V} \setminus \mathcal{U}$ ter povezave, ki imajo en konec povezave v množici \mathcal{U} , drugega pa v množici $\mathcal{V} \setminus \mathcal{U}$. Slika 2.11 podaja primer takšne delitve. Po definiciji je torej prerez \mathcal{C} množica povezav, za katere velja:

- $(u, v) \in \mathcal{E}$,
- $u \in \mathcal{U}$,
- $v \in \mathcal{V} \setminus \mathcal{U}$.

Kapaciteta prereza \mathcal{C} v grafu \mathcal{G} :

- $c(\mathcal{C}) = \sum_{e \in \mathcal{C}} c(e)$.

Za st-prerez velja:

- $s \in \mathcal{U}$,
- $t \in \mathcal{V} \setminus \mathcal{U}$.

Najmanjši st-prerez. Za podano st-pretočno omrežje obstaja tak st-prerez, da nobeden drugi prerez nima manjše vrednosti. V angleščini iskanju najmanjšega prereza v omrežju pravimo *minimum cut* oziroma krajše kar *min-cut* [32, str. 893].

Med iskanjem največjega pretoka v grafu \mathcal{G} in najmanjšega prereza v grafu \mathcal{G} velja ekvivalenčna relacija, ki ji z angleško frazo pravimo tudi *maxflow-mincut theorem* [32, str. 892]. Bralcu, ki bi se rad prepričal v pravilnost naših trditev, svetujemo, da prične v četrtem poglavju v delu [32], ki smo mu sledili tudi sami. Podrobnejšo razlago lahko dobi v poglavju o grafih v delu [13]. Tukaj jo bomo samo zapisali:

Izrek 2.1 (Največji pretok/najmanjši prerez [13, str. 723]) Če je tok f v grafu $\mathcal{G} = (\mathcal{V}, \mathcal{E})$, kjer je vozlišče s izvor, vozlišče t pa ponor, potem so naslednje relacije ekvivalentne:

1. f je največji pretok v \mathcal{G} .
2. Graf ostanka \mathcal{G}_f ne vsebuje več nobene poti, ki bi ji lahko povečali tok.
3. $|f| = c(s, t)$ za nek prerez (s, t) v \mathcal{G} .

2.5.2 Iskanje največjega pretoka/najmanjšega prereza

Eden izmed prvih uspešnih algoritmov za iskanje največjega pretoka v omrežju je poimenovan po svojih avtorjih, imenuje se *Ford-Fulkerson* (predstavlja celotno družino algoritmov z različnimi časovnimi zahtevnostmi izvajanja [13, str. 714]). Gre za splošno metodo postopnega povečevanja toka po povezavah od izvora do ponora. Algoritem uvrščamo v množico metod za povečevanje pretoka (v angleščini jim pravimo *augmenting-path* algoritmi). Da algoritem deluje v vseh danih okoliščinah, je potrebno vpeljati še nekaj dodatnih pravil. Predstavili bomo rešitev na podlagi omrežja oziroma grafa ostanka, za katero velja:

- vsebuje povezave, kjer je tok $f(e) < c(e)$,
- vsebuje obratne povezave, kjer je tok $f(e) > 0$.

Sedgewick [32, str. 892] na kratko poda opis delovanja algoritma. Pričnemo z ničelnim tokom na vseh povezavah. Dokler v grafu ostanka obstaja pot za povečanje pretoka (za vse povezave, ki vodijo naprej, je količina pretoka manjša od kapacitete povezave; za vse obratne povezave velja, da je trenutni tok večji od nič), ki teče od izvora do ponora, povečujemo pretok. Opis v psevdokodi lahko bralec najde pod zapisom Algoritma 1, prikaz poteka pa na Sliki 2.12.

Metoda Ford-Fulkerson ima znane težave ob napačni izbiri poti med povečevanjem pretoka [32, str. 894]. Časovna zahtevnost metode je odvisna od načina, kako določimo pot, po kateri bomo povečevali količino pretoka, in kakšne količine dopuščamo v grafu. Če dovolimo iracionalna števila, lahko izrojeni primeri vodijo v neskončne zanke [13, str. 725]). Rešitev za to predstavlja Algoritem 2. Razširitev je v načinu izbire poti za povečanje pretoka, ki ga algoritem Edmonds-Karp izbere kot najkrajšo pot od izvora do ponora. Seveda obstaja cela množica metod in algoritmov za reševanje problema najmanjšega reza oziroma največjega pretoka. Na tem mestu podajamo le seznam v Tabeli 2.1.

Algoritem 1 Ford-Fulkerson [13, str. 724]

```

1: for each edge  $(u, v) \in E$  do
2:    $(u, v).flow = 0$ 
3: end for
4: while there exists a path from  $s$  to  $t$  in the residual network  $G_f$  do
5:    $c_f(p) = \min(c_f(u, v) : (u, v) \in p)$ 
6:   for each edge  $(u, v) \in p$  do
7:     if  $(u, v) \in E$  then
8:        $(u, v).flow = (u, v).flow + c_f(p)$ 
9:     else
10:       $(v, u).flow = (v, u).flow - c_f(p)$ 
11:    end if
12:   end for
13: end while

```


Algoritem 2 Edmonds-Karp [13, str. 727]

```


1: for each edge  $(u, v) \in E$  do
2:    $(u, v).flow = 0$ 
3: end for
4: while there exists a shortest path from  $s$  to  $t$  in the residual network  $G_f$  do
5:    $c_f(p) = \min(c_f(u, v) : (u, v) \in p)$ 
6:   for each edge  $(u, v) \in p$  do
7:     if  $(u, v) \in E$  then
8:        $(u, v).flow = (u, v).flow + c_f(p)$ 
9:     else
10:       $(v, u).flow = (v, u).flow - c_f(p)$ 
11:    end if
12:   end for
13: end while

```


Slika 2.12: Prikaz poteka metode Ford-Fulkerson za izračun največjega pretoka oziroma najmanjšega prereza v podanem grafu. Metoda temelji na povečevanju pretoka po poti, najdeni v grafu ostanka. Vozlišče v_1 v spodnjem grafu predstavlja izvor, vozlišče v_5 pa ponor [32, str. 899].




(a) Na poti v_0, v_1, v_3, v_5 povečamo povezavam tok za dve enoti




(b) Med vozliščema v_1 in v_3 se pojavi obratna povezava; na poti v_0, v_2, v_4, v_5 povečamo povezavam tok za eno enoto



(c) Povezava med vozliščema v_2 in v_4 postane zasičena; na poti $v_0, v_2, v_3, v_1, v_4, v_5$ povečamo povezavam tok za eno enoto




(d) Zasičeni povezavi med vozliščema v_1 in v_4 ter v_2 in v_3 ; v grafu ostanka več ne obstaja pot od izvora od ponora, ki bi ji lahko povečali tok



(e) Graf je razpadel na dve disjunktni množici vozlišč: $v_0, v_2 \in \mathcal{U}$ in $v_1, v_3, v_4, v_5 \in \mathcal{V} \setminus \mathcal{U}$. Najmanjši prerez tvorijo povezave, ki vodijo iz \mathcal{U} v $\mathcal{V} \setminus \mathcal{U}$ in znaša štiri enote

Tabela 2.1: Seznam algoritmov za iskanje največjega pretoka oziroma najmanjšega prereza v grafu [18].

Leto	Avtor	Zahtevnost
1951	Dantzig	$O(n^2mU)$
1955	Ford in Fulkerson	$O(m^2U)$
1970	Dinitz	$O(n^2m)$
1972	Edmonds in Karp	$O(m^2 \log U)$
1973	Dinitz	$O(nm \log U)$
1974	Karzanov	$O(n^3)$
1977	Cherkassky	$O(n^2m^{1/2})$
1980	Galil in Naamad	$O(nm \log^2 n)$
1983	Sleator in Tarjan	$O(nm \log n)$
1986	Goldberg in Tarjan	$O(nm \log(n^2/m))$
1987	Ahuja in Orlin	$O(nm + n^2 \log U)$
1987	Ahuja in sodelavci	$O(nm \log(n\sqrt{\log U}/m))$
1989	Cheriyani in Hagerup	$E(nm + n^2 \log^2 n)$
1990	Cheriyani in sodelavci	$O(n^3 / \log n)$
1990	Alon	$O(nm + n^{8/3} \log n)$
1992	King in sodelavci	$O(nm + n^{2+\epsilon})$
1993	Phillips in Westbrook	$O(nm(\log_{m/n} n + \log^{2+\epsilon} n))$
1994	King in sodelavci	$O(nm \log_{m/(n \log n)} n)$
1997	Goldberg in Rao	$O(m^{3/2} \log(n^2/m) \log(U))$ $O(n^{2/3}m \log(n^2/m) \log(U))$

Slika 2.13: Skica izgradnje grafa G

2.5.3 Prevedba segmentacije na iskanje minimalne energije v grafu

Končno podajmo še teoretično podlago za prevedbo binarne segmentacije na iskanje minimalne energije v grafu po metodi *graph cuts* [23]. Naša osnova je delo, ki sta ga opravila Yuri Boykov in Gareth Funk-Lea [6]. Število vozlišč v grafu je določeno s številom slikovnih elementov, ki sestavljajo sliko. Definirajmo to kot množico \mathcal{P} . Naj množica \mathcal{N} predstavlja sistem sosednosti: par vozlišč $\{p, q\} \in \mathcal{N}$, vozlišči p in q pa hkrati pripadata $p, q \in \mathcal{P}$. Graf vsebuje še dve dodatni vozlišči, ki se imenujeta izvor s in ponor t (Slika 2.13).


Naša naloga je ločiti grčo (objekt) od zdravega lesa (platno). Zato definirajmo binarni vektor $\vec{a} = (a_1, a_2, \dots, a_p, \dots, a_{|\mathcal{P}|})$, kjer a_p predstavlja točno določeno označbo p v \mathcal{P} . Vektor \vec{a} torej določa binarno segmentacijo \mathcal{P} . Vsaka oznaka a_p lahko pripada bodisi objektu (FG) bodisi platnu (BG). FG je kratica za angleško besedo *foreground* oziroma ospredje, BG pa kratica za angleško besedo *background* ali ozadje.

Funkcija, ki jo optimiziramo v našem primeru, je:

$$E(\vec{a}) = \lambda \cdot R(\vec{a}) + B(\vec{a}), \quad (2.2)$$

kjer

$$R(\vec{a}) = \sum_{p \in \mathcal{P}} R_p(a_p), \quad (2.3)$$



Slika 2.14: Primer razlike med intenzitetno histogramsko porazdelitvijo za ozadje in ospredje. Porazdelitve lahko dobimo interaktivno s pomočjo semen ali se jih naučimo iz primerno označenih učnih primerov.

$$B(\vec{a}) = \sum_{p \in \mathcal{P}} \sum_{\{p,q\} \in \mathcal{N}} B_{\{p,q\}} \cdot \delta(a_p, a_q) \quad (2.4)$$

in

$$\delta(a_p, a_q) = \begin{cases} 1 & a_p \neq a_q \\ 0 & a_p = a_q \end{cases}. \quad (2.5)$$


$R(\vec{a})$ in $B(\vec{a})$ iz (2.2) sta t. i. območni in mejni del optimizacijskega kriterija; λ določa razmerje med prispevkom območnega in mejnega dela. Območni kriterij (2.3) določa utež, ali a_p pripada ospredju ali ozadju. Primer, kako lahko iz $R(\cdot)$ dobimo uteži, podajata (2.6) in (2.7).

$$R_p(FG) = -\ln \Pr(I_p|FG), \quad (2.6)$$

$$R_p(BG) = -\ln \Pr(I_p|BG), \quad (2.7)$$

kjer je $\Pr(I_p|FG)$ verjetnost, da pripada slikovni element p ospredju ter $\Pr(I_p|BG)$ verjetnost, da pripada slikovni element p ozadju.

Slika 2.14 prikazuje, kako se lahko iz učne množice, kjer imamo poznano ločnico med zdravim lesom in grčami, naučimo intenzitetno histogramsko porazdelitev. Če pogledamo zgornjo vrstico Slike 2.15, lahko opazimo, da skladno z (2.6) in (2.7) ter naučeno intenzitetno histogramsko porazdelitvijo



Slika 2.15: Primer razlike posameznega slikovnega elementa na zdravem lesu in grči

obstaja večja verjetnost, da levi slikovni element pripada ozadju kot ospredju, ter da je večja verjetnost, da desni slikovni element pripada ospredju kot ozadju.

Mejni kriterij (2.4) opiše lastnosti razmejitve segmentacije: člen $B_{\{p,q\}}$ je velik, kadar sta slikovna elementa p in q podobna, in blizu ničle, kadar sta slikovna elementa p in q zelo različna. Kadar pravimo podobna oziroma različna, imamo v mislih neko mero podobnosti, npr. intenziteto ali barvo.

$$B_{\{p,q\}} \propto \exp \left(-\frac{(I_p - I_q)^2}{2\sigma^2} \right) \cdot \frac{1}{d(p,q)}, \quad (2.8)$$

kjer je

$$d(p,q) = \sqrt{(q_x - p_x)^2 + (q_y - p_y)^2}. \quad (2.9)$$

Pozoren bralec je morda že sam ugotovil, da gre pri podani enačbi za mero na podlagi razlike v intenziteti. I_p in I_q sta tako intenziteti slikovnih elementov p in q ; σ je parameter, ki kaznuje diskontinuitete med slikovnimi elementi podobnih intenzitet. Kadar je $|I_p - I_q| < \sigma$, je kazen velika, kadar pa $|I_p - I_q| > \sigma$, je kazen majhna. Primer podaja Slika 2.15 v spodnji vrstici.

V Tabeli 2.2 podajmo še na enem mestu zbrana pravila za konstrukcijo grafa \mathcal{G} , v katerem s pomočjo rešitve problema minimalnega reza rešimo problem segmentacije med objektom in ozadjem [6, str. 120]. Pri tem velja,

Tabela 2.2: Pravila za prevedbo problema binarne segmentacije na izračun največjega pretoka ali najmanjšega reza v grafu [6, str. 120]

Tip	Povezava	Utež	Pogoj
n-link	$\{p, q\}$	$B_{\{p,q\}}$	$\{p, q\} \in \mathcal{N}$
t-link	$\{p, s\}$	$\lambda \cdot R_p(BG)$	$p \in \mathcal{P}, p \notin \mathcal{O} \cup \mathcal{B}$
		ν	$p \in \mathcal{O}$
		0	$p \in \mathcal{B}$
t-link	$\{p, t\}$	$\lambda \cdot R_p(FG)$	$p \in \mathcal{P}, p \notin \mathcal{O} \cup \mathcal{B}$
		0	$p \in \mathcal{O}$
		ν	$p \in \mathcal{B}$

da je

$$\nu = 1 + \max_{p \in \mathcal{P}} \sum_{q: \{p,q\} \in \mathcal{N}} B_{p,q} \quad (2.10)$$

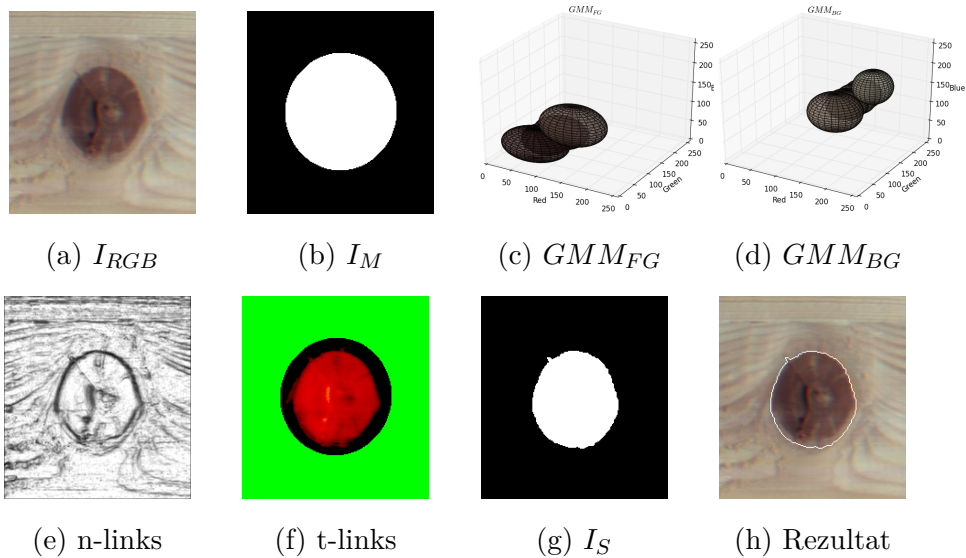
Poglavje 3

Predlagana segmentacija in lokalizacija grče

Cilj diplomskega dela je uspešno rešiti problem fine lokalizacije grče v lesu. V podpoglavju 2.5 smo podali teoretično ozadje za prevedbo binarne segmentacije na iskanje najmanjšega prereza v grafu, sedaj pa podajmo še podrobnosti predlagane metode, ki jo bomo poimenovali z angleško skovanko *Knotcut*. V angleški jezik grčo prevedemo kot *wood knot*. Fraza *to cut out* pa v prevodu pomeni izrezati. Hkrati s tem pretkano uporabimo besedo *cut*, ki je sestavni del metode *graph cuts*. V veliko pomoč pri odkrivanju podrobnosti pri definiciji metode sta nam bili deli, ki so ga opravili Rother in sodelavci v [31] ter Talbot in Xu v [36]. Na Sliki 3.1 podajamo spremljajoče slikovno gradivo, ki je lahko bralcu v pomoč pri razumevanju podanega postopka.

Vhodno sliko vraščene grče I_{RGB} (Slika 3.1a) in njeno pripadajočo grobo lokalizacijo, podano kot masko I_M (Slika 3.1b), uporabimo za, prvič, učenje verjetnostne porazdelitve mešanice Gaussov (Sliki 3.1c in 3.1d), in drugič, kot seme za fiksni del inicializacije metode *graph cuts*. Na podlagi naučenih modelov GMM izračunamo območne (Slika 3.1e) in mejne (Slika 3.1f) uteži ter izgradimo graf. Rezultat izračuna minimalnega prereza grafa sta dve ločeni regiji, kjer ena pripada grči, druga pa lesu, podani kot izhodna maska I_S (Slika 3.1g).

Slika 3.1: Sliki 3.1a in 3.1b sta vhodna podatka v algoritem. Na Slikah 3.1c in 3.1d smo prikazali modela GMM za ospredje in ozadje, pridobljena na podlagi vhodne slike I_{RGB} in maske I_M . Prikaz območnih in mejnih uteži lahko vidimo na Slikah 3.1e in 3.1f. Rezultat segmentacije je prikazan na Sliki 3.1g: izhodna maska I_S – področje grče je predstavljeno z belo barvo, področje lesa pa s črno barvo. Za lažjo predstavbo smo mejo med dobljenima regijama vrisali na vhodno sliko I_{RGB} in jo prikazali na Sliki 3.1h.



Dve ključni komponenti sistema sta pridobitev verjetnostne porazdelitve za grčo in ozadje ter učinkovit izračun najmanjšega prereza v grafu. Pri tem smo sledili priporočilu v [6, str. 117 in 128]. V prvem primeru smo sledili delu [31], v drugem pa [9].

3.1 Učenje modela mešanice Gaussovih porazdelitev

S pomočjo algoritma maksimizacije pričakovanja (angl., expectation maximization algorithm, EM) pridobimo modele barvnih mešanic Gaussovih porazdelitev, ki jih bomo uporabili skladno z (2.6) in (2.7). Teoretično razlago učenje modela mešanice Gaussovih porazdelitev povzemamo po delu [5, str. 110–113]. Verjetnostno porazdelitev opazovanih podatkov $p(\vec{x})$ lahko predstavimo kot superpozicijo K Gaussovih porazdelitev oblike

$$p(\vec{x}) = \sum_{k=1}^K \pi_k \mathcal{N}(\vec{x} | \vec{\mu}_k, \Sigma_k), \quad (3.1)$$

kjer je $\mathcal{N}(\vec{x} | \vec{\mu}_k, \Sigma_k)$ posamezna Gaussova funkcija gostote verjetnosti z vektorjem pričakovane vrednosti $\vec{\mu}_k$, kovariančno matriko Σ_k ter utežmi π_k . Takšno linearno kombinacijo superpozicij osnovnih Gaussovih verjetnostnih porazdelitev imenujemo mešanica Gaussovih porazdelitev (GMM). Pri tem pa morata veljati naslednja pogoja:

$$\sum_{k=1}^K \pi_k = 1 \text{ in } 0 \leq \pi_k \leq 1. \quad (3.2)$$

Obliko mešanic Gaussovih porazdelitev tako določajo parametri $\vec{\mu}$, Σ in $\vec{\pi}$. Vrednost teh parametrov lahko določimo tako, da maksimiziramo kriterijsko funkcijo:

$$\ln p(X | \vec{\pi}, \vec{\mu}, \Sigma) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(\vec{x}_n | \vec{\mu}_k, \Sigma_k) \right\}. \quad (3.3)$$

Tako oblikovana kriterijska funkcija nima analitične rešitve. Za rešitev problema se opremo na iterativni numerični postopek EM. Podajmo še iterativno

shemo algoritma EM [5, str. 438,439], primer izvajanja lahko vidimo na Sliki 3.2:

1. Začetna inicializacija parametrov pričakovanih vrednosti $\vec{\mu}_k$, kovariančnih matrik Σ_k ter uteži π_k in določitev začetne vrednosti kriterijske funkcije logaritma verjetnosti.
2. Korak E. Na podlagi trenutnih parametrov modela izračunamo funkcijo

$$\gamma(z_{n,k}) = \frac{\pi_k \mathcal{N}(\vec{x}_n | \vec{\mu}_k, \Sigma_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(\vec{x}_n | \vec{\mu}_j, \Sigma_j)}. \quad (3.4)$$

3. Korak M. Ponovno ocenimo vrednosti parametrov glede na trenutno vrednost funkcije $\gamma(z_{n,k})$

$$\vec{\mu}'_k = \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{n,k}) \vec{x}_n \quad (3.5)$$

$$\Sigma'_k = \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{n,k}) (\vec{x}_n - \vec{\mu}'_k)(\vec{x}_n - \vec{\mu}'_k)^\top \quad (3.6)$$

$$\vec{\pi}'_k = \frac{N_k}{N}, \quad (3.7)$$

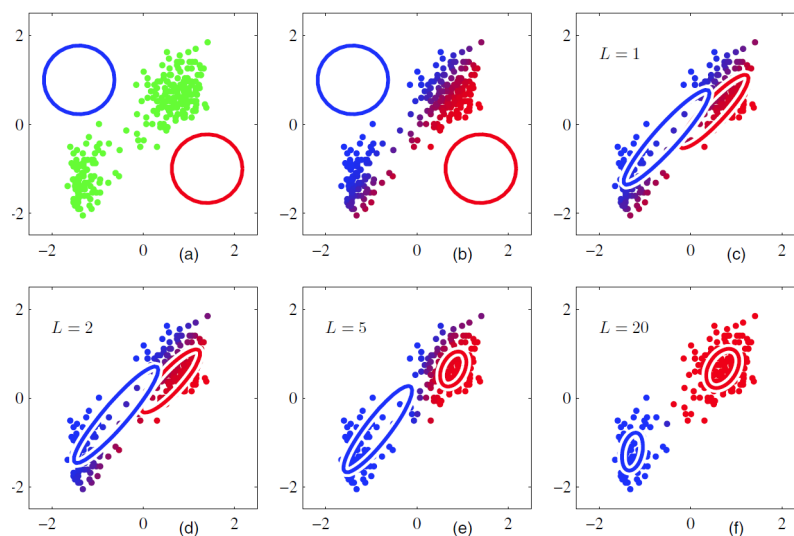
kjer velja, da je

$$N_k = \sum_{n=1}^N \gamma(z_{n,k}). \quad (3.8)$$

4. Sledi izračun kriterijske funkcije logaritma verjetnosti

$$\ln p(X | \vec{\pi}, \vec{\mu}, \Sigma) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(\vec{x}_n | \vec{\mu}_k, \Sigma_k) \right\} \quad (3.9)$$

ter preverjanje konvergenčnih kriterijev bodisi parametrov bodisi kriterijske funkcije. Če ti niso izpolnjeni, se vrnemo na drugi korak.

Slika 3.2: Prikaz poteka EM algoritma za $K = 2$ [5, str. 437]

3.2 Algoritem Boykov-Kolmogorov

Yuri Boykov in Vladimir Kolmogorov sta v delu [9] predstavila nov algoritem za iskanje najmanjšega prereza oziroma največjega pretoka v grafih iz družine postopnega povečevanja pretoka. V našem delu smo uporabili implementacijo njunega algoritma, ki jo lahko najdemo na [8]. Prav tako kot Dinic [9, str. 9] sta uporabila iskalno drevo za iskanje poti za povečanje pretoka z dvema ključnima izboljšavama. Prva novost je ločena uporaba dveh dreves; eno išče v smeri od izvora s , drugo pa v smeri od ponora t . Druga je ponovna uporaba že ustvarjenih iskalnih dreves brez ponovnega preiskovanja celotnega prostora od začetka. Algoritem v glavni zanki poteka v treh fazah. Prva je rast dreves (angl., *grow*), druga je povečevanje pretoka (angl., *augment*), tretja je ponovno vzpostavljanje celovitosti iskalnih dreves (angl., *adopt*). Grob oris lahko vidimo na prikazu Algoritma 3; pri tem velja, da so A aktivna ter P pasivna vozlišča. Podajmo še opis posameznih faz [9, str. 9–11]:

1. V fazi rasti se razširita iskalni drevesi, dokler ni uspešno najdena pot od izvora s do ponora t . Širitev poteka na podlagi seznama aktivnih vozlišč

A , kjer se v iskalno drevo dodajajo prosta vozlišča, ki so povezana z nezasičenimi povezavami, ta postanejo aktivna. Ko so preiskani vsi sosedji, vozlišče postane pasivno. Rast se ustavi, ko aktivno vozlišče iz enega drevesa naleti na vozlišče iz drugega drevesa. Primer lahko vidimo na sliki 3.3.

2. V fazi povečevanja pretoka po najdeni poti se poveča največji možen pretok. Tako postanejo nekatere povezave zasičene, povezana vozlišča pa sirote. Posledično lahko drevesi S in T postaneta gozdova.
3. V fazi posvojitve se poizkuša ponovno vzpostaviti celovitost iskalnih dreves. Vsako osirotelo vozlišče se poizkuša povezati po nezasičeni povezavi bodisi k iskalnemu drevesu S bodisi k T . Če to ne uspe, vozlišče postane prosto, vsi njegovi potomci pa sirote. Faza se zaključi, kadar ni več osirotelih vozlišč.


Potek iskanja največjega pretoka oziroma najmanjšega prereza se zaključi, kadar iskalni drevesi S in T ne moreta več rasti. To pomeni, da je množica aktivnih vozlišč prazna, drevesi pa sta med seboj ločeni z zasičenimi povezavami.

Algoritem 3 Boykov-Kolmogorov [9, str. 11]

```

1: initialize:  $S = \{s\}$ ,  $T = \{t\}$ ,  $A = \{s, t\}$ ,  $O = \emptyset$ 
2: while true do
3:   grow  $S$  or  $T$  to find an augmenting path  $P$  from  $s$  to  $t$ 
4:   if  $P = \emptyset$  then
5:     terminate
6:   end if
7:   augment on  $P$ 
8:   adopt orphans
9: end while
```

Čeprav ima algoritem slabšo teoretično kompleksnost kot na primer Dinicev, pa sta avtorja na problemih iz področja računalniškega vida pokazala,



Slika 3.3: Primer poteka algoritma Boykov-Kolmogorov. Iskalni drevesi S (rdeča vozlišča) in T (modra vozlišča) ob koncu faze rasti, ko je najdena pot (rumena črta) od izvora s do ponora t . Aktivna in pasivna vozlišča so označena s črkama A in P . Prosta vozlišča so brez oznake [9, str. 9].

da je ta v praksi od dva- do petkrat hitrejši [9, str. 29, 30].

3.3 Algoritem za segmentacijo grč *Knotcut*

1. Vhod v algoritem sta 24-bitna barvna slika I_{RGB} in 8-bitna črno-bela maska I_M . Področje, kjer se nahaja grča, je na maski označeno z belo barvo, ozadje oziroma les pa s črno.
2. Na podlagi vhodnih podatkov slike I_{RGB} in maske I_M ustvarimo dva ločena modela mešanice Gaussovih porazdelitev; en za grčo ter en za ozadje. Vsak je predstavljen kot superpozicija petih Gaussovih porazdelitev s parametri $\vec{\mu}$, Σ ter $\vec{\pi}$.
3. Izračunamo uteži za območne (t -links) in mejne (n -links) povezave, skladno s Tabelo 2.2. Pri tem pripišemo črno področje maske razredu ozadja oziroma lesa. Na ta način torej uporabimo del maske kot seme za segmentacijo. Območne uteži, ki sledijo (2.6) in (2.7), dobijo obliko

$$R_p = -\log \sum_{i=1}^K \pi_i \frac{1}{\sqrt{|\Sigma_i|}} \exp \left(-\frac{1}{2} [I_p - \mu_i]^T \Sigma_i^{-1} [I_p - \mu_i] \right), \quad (3.10)$$

pri tem velja, da je $\nu = 8 \cdot \gamma + 1$ in $\gamma = 50$. Za mejne uteži sledimo (2.8), ki jo prevedemo v obliko

$$B_{\{p,q\}} = \frac{\gamma}{d(p,q)} \cdot \exp \left(-\beta \|I_p - I_q\|^2 \right), \quad (3.11)$$

kjer je

$$\beta = \frac{1}{2\langle \|I_p - I_q\|^2 \rangle}. \quad (3.12)$$

Pri izračunu območnih uteži v (3.10) nastopajo naslednji pojmi:

- $|\Sigma_i|$ – determinanta kovariančne matrike Σ ,
- Σ_i^{-1} – inverz kovariančne matrike Σ .

Neznane količine ob izračunu mejnih uteži v (3.11) in (3.12) so:

- $d(p, q)$ – evklidska razdalja med slikovnima elementoma p in q ,
 - $\|I_p - I_q\|^2$ – kvadrat evklidske norme razlike intenzitet slikovnih elementov p in q ,
 - $\langle \|I_p - I_q\|^2 \rangle$ – matematično upanje evklidske norme razlike intenzitet slikovnih elementov p in q za celotno sliko I . Za enakomerne porazdelitve je matematično upanje kar aritmetično povprečje.
4. Z izračunanimi območnimi in mejnimi utežmi zgradimo graf ter izvedemo algoritem Boykov-Kolmogorov za izračun minimalnega prereza.
 5. Rezultat izračuna minimalnega prereza prevedemo v 8-bitno črno-belo masko I_S , ki predstavlja rezultat segmentacije. Pri tem velja, da je področje grče bele barve, področje ozadja pa črne barve.


Poglavje 4

Eksperimentalna analiza


4.1 Sistem za zajem podatkov

Za iskanje napak v lesu lahko na trgu najdemo avtomatizirane sisteme različnih proizvajalcev. V Evropi prisotna in bolj prepoznavna sta italijanski proizvajalec Microtec [28] s sistemom Goldeneye [27] ter švedski WoodEye AB [39] s sistemom WoodEye 5 [1]. Kot primer tipičnega sistema navedimo Microtecovo napravo serije Goldeneye 500, ki omogoča optično kontrolo na podlagi različnih modalitet, s katerimi poizkušamo določiti strukturo opazovane snovi: barvni zajem, rentgenski zajem oziroma žarki X, zajem na podlagi laserskega sipanja (usmerjenost vlaken), 3D-laserska triangulacija ter laserska interferometrija [27]. Primer zajema takega sistema si lahko ogledamo na Sliki 4.1.

Naša podatkovna zbirka je pridobljena iz slik, zajetih pri enem izmed slovenskih proizvajalcev opažnih plošč na stroju za avtomatsko krpanje grč s pomočjo optične kontrole. Med proizvodnim procesom se polizdelek zapelje skozi sistem za optično kontrolo, ki je proizvod podjetja Kolektor Orodjarna d. o. o., PC Vision (Slika 4.2). Naprava je funkcionalno sorodna prej omenjenima, za naš namen pa bomo uporabili podatke, pridobljene s pomočjo barvne linijske kamere. Na Sliki 4.3 je možno videti potek obdelave ene lesene plošče.



Slika 4.1: Primer zajetih različnih modalitet optične kontrole serije Golde-
neye 500 proizvajalca Microtec: barvni zajem, rentgenski zajem oziroma žarki
X, zajem na podlagi laserskega sipanja (usmerjenost vlaken), 3D–laserska tri-
angulacija, laserska interferometrija [27]



Slika 4.2: Skica našega eksperimentalnega sistema za zajem barvne slike. Preprosto izvedbo v osnovi sestavljajo mehanska konstrukcija, skozi katero se zapelje iz več desk zlepljena lesena plošča, ter optični del, ki ga sestavljata linijska barvna kamera in linijski svetilni vir. Med mehanskim in optičnim sklopom tvori povezavo števec obratov, ki poskrbi za sinhronizacijo med dejanskim pomikom lepljene lesene plošče ter trenutkom zajema linijske kamere. Ta sinhronizacijski mehanizem je nujno potreben, da dobimo sliko, ki odraža pravo razmerje glede na resnične mere deske v prečni in vzdolžni smeri. Za naš sistem znaša razmerje med slikovnimi elementi in mero v milimetrih $0,407\,809\,8 \frac{px}{mm}$, torej vsak slikovni element predstavlja približno 0,4 mm v naravi.


Slika 4.3: Sistema za avtomatsko krpanje grč opažnih plošč, katerega optično kontrolo s programsko opremo je izdelalo podjetje Kolektor Orodjarna d. o. o., PC Vision. (4.3a) Zaradi postopka obdelave plošče prihajajo na kontrolo v paketih. (4.3b) Na nadzornem zaslonu lahko operater opazuje delovanje sistema in po potrebi prilagaja kontrolne parametre sistema optične kontrole. (4.3c) Za zagotavljanje kontroliranega potovanja desk skozi optično kontrolo so te trdno vpete v horizontalni in vertikalni smeri. Sinhronizacijo med pomikom in zajemom zagotavlja števec obratov.



(a) Paket zlepljenih desk v zalogovniku čaka na pregled sistema za optično kontrolo



(b) Sistem optične kontrole z nadzornim zaslonom



(c) Zlepljena deska na poti skozi optično kontrolo. Na sliki lahko dobro vidimo stransko in zgornjo oporo za kontroliran prehod skozi sistem.

4.2 Programsko orodje KiS

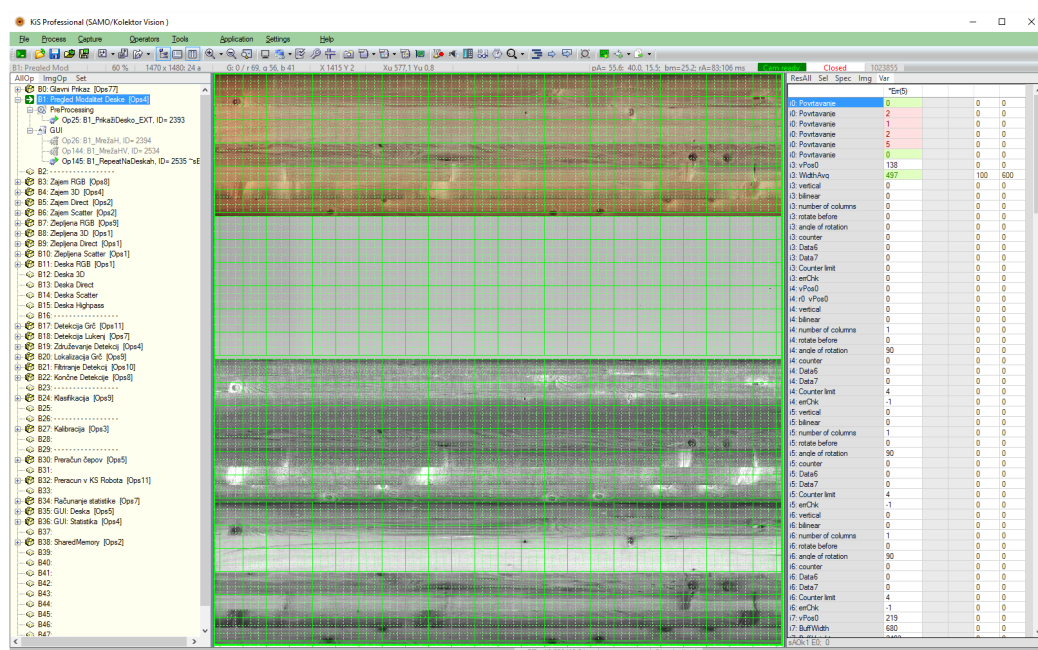
Sistem optične kontrole deluje na osnovi programskega orodja KiS (*Kolektor Imaging Software*). Gre za programsko orodje za razvoj aplikacij za strojni vid, namenjenih predvsem industrijskemu okolju. Program KiS predstavljamo z namenom širše prepoznavnosti programske opreme, ki je plod znanja in dela slovenskih inženirjev in je na trgu prisoten skozi različne inkarnacije že 17 let.

Njegove prednosti so v hitrem razvoju naprednih aplikacij s pomočjo standardnih gradnikov po principu *kar vidiš, boš tudi dobil* (angl., *What You See Is What You Get*; zapisano krajše z angleškim akronimom WYSIWYG). Programska oprema že v osnovi podpira širok nabor kamer, programabilnih logičnih krmilnikov, aktuatorjev in druge strojne opreme. Standardni programski moduli omogočajo širok nabor operacij za obdelavo in analizo slike. S pomočjo intuitivnega uporabniškega vmesnika za časovni potek izvajanje aplikacije je mogoče preprosto definirati potek programa. Uporabnik lahko takoj vidi rezultate svojega dela na podlagi bogatega nabora različnih grafičnih gradnikov ali jih posreduje preko različnih komunikacijskih protokolov v nadaljnjo obdelavo (rs232, tcp, profinet, datoteke ...). Resnično univerzalnost je mogoče doseči s pomočjo programskih razširitev, ki jih definira aplikacijski programski vmesnik. Za preprosta opravila je na voljo skriptni jezik .Net, zahtevnejše naloge pa lahko udejanjimo v zunanjem modulu dll, ki ga preprosto pritaknemo programu. Na Sliki 4.4 lahko vidimo delovanje programa v dveh načinih: prvi, razvijalski, prikazuje primer združenega pogleda različnih tipov kamer, drugi pa aktivne aplikacije za povrtavanje grč.

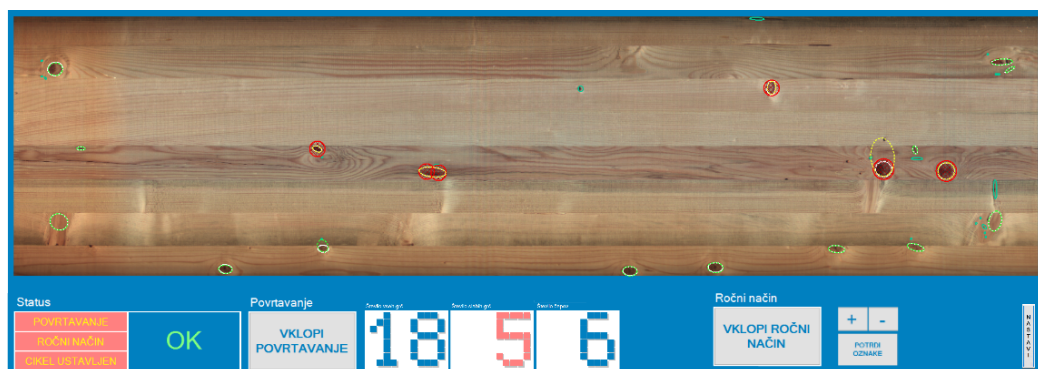
4.3 Zbirka slik grč

Podatkovna zbirka je bila zajeta na stroju za avtomatično krpanje grč v procesu proizvodnje opažnih plošč. Primer detekcije grč prej opisanega sistema, katerega grafični vmesnik smo lahko videli na Sliki 4.4b, lahko sedaj vidimo na Sliki 4.5. Da se obvarujejo podrobnosti o zmogljivosti delovanja stroja,

Slika 4.4: Programsko orodje KiS (*Kolektor Imaging Software*) podjetja Kolektor Orodjarna d. o. o., PC Vision. (4.4a) Osnovni pogled, v katerem nastajajo rešitve strojnega vida. Na osrednjem predelu razvojnega okolja lahko vidimo združen prikaz različnih modalitet sistema za povrtavanje grč. (4.4b) Nadzorni zaslon aplikacije za avtomatično povrtavanje grč, kjer lahko operater po potrebi prilagaja kontrolne parametre sistema optične kontrole, hkrati pa opazuje delovanje stroja.

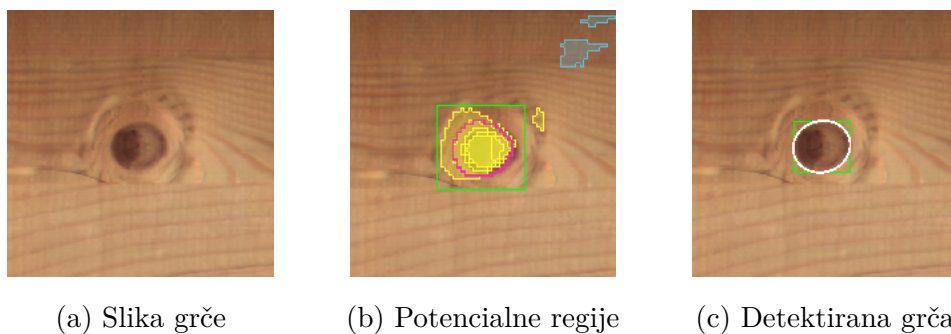


(a) KiS v načinu za izdelavo aplikacij (t. i. *KiS design mode*)



(b) Aplikacija za optično kontrolo (t. i. *KiS online mode*)

Slika 4.5: Primer detekcije grče naprave za optično kontrolo. (4.5a) Grčo lahko vidimo v zgornjem levem kotu aplikacije za optično kontrolo na Sliki 4.4b. (4.5b) Večplastni sistem detekcije za natančno določanje pozicije grče (4.5c) Končni rezultat segmentacije, ki je potencialno posredovan sistemu za povrtavanje grč.



smo podatke o natančni segmentaciji zavrgli.

Podatke za našo eksperimentalno fazo smo tako pridobili na dva načina. Pri prvem načinu so oznake pridobljene z obdelavo podatkov, pridobljenih na podlagi optične analize stroja, pri drugem pa predmet ročnega označevanja istih podatkov.

Vse avtomatično pridobljene maske smo dobili na podlagi izračuna elips, pridobljenih iz slikovnih značilnic t. i. momentov. Postopek pridobivanja usmerjene elipse na podlagi momentov povzemamo po delu Petra Corka [12, str. 351, 352]. Osnovo predstavlja binarizirana slika I , moment $m_{p,q}$ pa izračunamo po enačbi:

$$m_{p,q} = \sum_{(u,v) \in I} u^p v^q I[u, v] \quad (4.1)$$

Centroid za regijo, ki jo predstavlja binarizirana slika, dobimo po enačbah:

$$u_c = \frac{m_{10}}{m_{00}} \quad (4.2)$$

in

$$v_c = \frac{m_{01}}{m_{00}}. \quad (4.3)$$

Na podlagi centroidov lahko izračunamo centralne momente:

$$\mu_{p,q} = \sum_{(u,v) \in I} (u - u_c)^p (v - v_c)^q I[u, v]. \quad (4.4)$$

Na podlagi prvih in drugih centralnih momentov dobimo kovariančno matriko:

$$J = \begin{bmatrix} \mu_{20} & \mu_{11} \\ \mu_{11} & \mu_{02} \end{bmatrix}. \quad (4.5)$$

Iz kovariančne matrike J lahko dobimo lastne vrednosti λ_i ter lastne vektorje \vec{v}_i , ki so neposredno povezani z orientacijo in velikostjo elipse. Osi r_a , r_b in usmerjenost θ elipse iz Slike 4.6b tako določimo na naslednji način, pri tem pa velja $\lambda_2 > \lambda_1$:

$$r_a = 2\sqrt{\frac{\lambda_2}{m_{00}}}, \quad (4.6)$$

$$r_b = 2\sqrt{\frac{\lambda_1}{m_{00}}}, \quad (4.7)$$

$$\theta = \tan^{-1} \frac{\vec{v}_{2y}}{\vec{v}_{2x}}. \quad (4.8)$$


Tako dobljeno sliko elipse I smo obdelali z morfološko operacijo širjenja g s strukturnim elementom s :

$$O[u, v] = g(I[u + i, v + j]), \forall (i, j) \in S, \forall (u, v) \in I \quad (4.9)$$

Za strukturni element S smo uporabili krog z radijem $r = 15,5$ slikovnih elementov. Pri tem naj opomnimo, da smo vrednost določili izkustveno. Na Sliki 4.6b je rdeča elipsa rezultat morfološke operacije širjenja zelene elipse. Končen rezultat in s tem pridobljena maska je prikazana na Sliki 4.6c. Več podrobnosti o morfološki operaciji širjenja in ostalih morfoloških operacijah si lahko bralec ogleda v poglavju 3.6 *Morphology* v delu [35].

Celotna zbirka vključuje 119 slik različnih grč s povprečno površino $\bar{S} = 1148 \text{ mm}^2$. Za lažjo predstavbo povejmo, da je to ekvivalentno krogu z radijem $r = 19,11 \text{ mm}$. Nekaj naključno izbranih primerov lahko vidimo na Sliki 4.7. Za zbirko smo statistično ovrednotili porazdeljenost površine, mali in veliki

Slika 4.6: Priprava podatkov za eksperimentalno delo je potekala tako, da smo na podlagi analize stroja za optično kontrolo določili področje, izven katerega grča ne nastopa. Iz pridobljene segmentirane površine smo na podlagi momentov določili usmerjeno elipso, ki smo jo nato obdelali z morfološko operacijo širjenja, primer Slika 4.6b in 4.6c. Opravili smo ročno označevanje vseh podatkov. Primer Slika 4.6d



radij, povprečno intenziteto za grčo in les ter standardne odklone intenzitete grč in lesa. Iz prikazanih grafov na Sliki 4.8 je mogoče razbrati, da so pridobljeni podatki približno normalno porazdeljeni (vrednosti podajamo v slikovnih elementih): površina s povprečno vrednostjo $\bar{S} = 6901$ in standardnim odklonom $\sigma_S = 2589$, radija r_a in r_b s povprečnima vrednostma $\bar{r}_a = 55,1$, $\bar{r}_b = 40,6$ in pripadajočima standardnima odklonoma $\sigma_{r_a} = 13,7$, $\sigma_{r_b} = 8,0$. V primeru orientacije elips gre za uniformno porazdelitev, kar nakazuje, da orientacije grč enakomerno pokrivajo prostor. Povprečne vrednosti intenzitete posameznega barvnega kanala grče so $\mu_r = 108,6$, $\mu_g = 83,4$, $\mu_b = 72,4$ za les pa $\mu_r = 162,4$, $\mu_g = 141,9$, $\mu_b = 119,7$ (Sliki 4.9a in 4.9b). Povprečne vrednosti standardnega odklona intenzitete za celotno podatkovno zbirko za grče znašajo $\sigma_r = 20,6$, $\sigma_g = 19,2$, $\sigma_b = 15,1$ za les pa $\sigma_r = 14,8$, $\sigma_g = 17,2$, $\sigma_b = 15,77$ (Sliki 4.9c in 4.9d).




Slika 4.7: Izbor različnih tipov grč. Podatke smo pridobili pri enem izmed slovenskih proizvajalcev opažnih plošč. Vidimo lahko raznolikost odtenkov in oblik, ki so prisotne v lesu.

Tabela 4.1: Na podlagi matrike napak (angl., *confusion matrix*) lahko določimo različne veličine [38, str. 164]

		Predviden razred	
		Pozitiven	Negativen
Resničen razred	Pozitiven	Resnično pozitiven	Neresnično negativen
	Negativen	Neresnično pozitiven	Resnično negativen


4.4 Mere zmogljivosti in postopek vrednotenja

V eksperimentalnem delu smo želeli ovrednotiti zmogljivost izbrane metode segmentacije. Osnovne merjene veličine podajamo v Tabeli 4.1, ki ji pravimo matrika napak. Na eni strani imamo podane resnične podatke, na drugi strani pa podatke, pridobljene na podlagi metode, ki jo vrednotimo. V našem primeru govorimo o podani maski, ki predstavlja resnično mejo med grčo in lesom, ter rezultatu segmentacije. Takšen način je pogosto uporabljen v



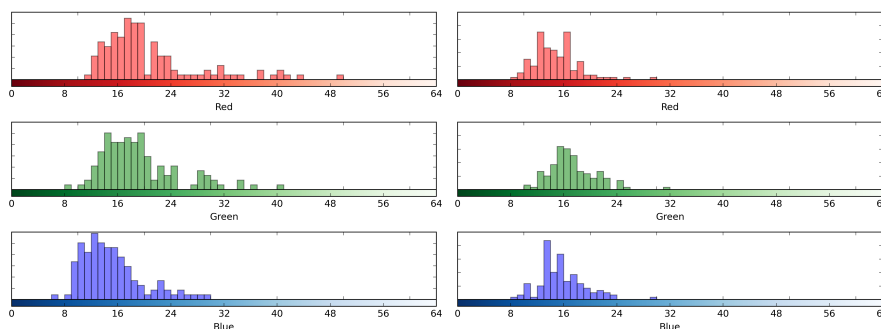
Slika 4.8: Grafični prikaz analize podatkovne zbirke grč. Graf levo zgoraj prikazuje porazdelitev površine grč v slikovnih elementih, pridobljene na podlagi ročne segmentacije. Graf desno zgoraj prikazuje porazdelitev orientacije grč. Spodnja grafa prikazujeta porazdelitev velikega, r_a , in malega, r_b , polmera elipse, pridobljene na podlagi momentov. Povprečne veličine za površino in radij znašajo $\bar{S} = 6901$, $\bar{r}_a = 55.1$, $\bar{r}_b = 40.6$, na grafih so prikazane z modro črtkano črto. Z rdečo črtkano črto smo želeli poudariti, da so podatki normalno porazdeljeni. Pripadajoči standardni odkloni za površino ter mali in veliki radij so $\sigma_S = 2589$, $\sigma_{r_a} = 13.7$, $\sigma_{r_b} = 8.0$.

Slika 4.9: Statistika podatkovne zbirke grč, pridobljena na podlagi ročno pridobljenih mask. Povprečne vrednosti intenzitete za celotno podatkovno zbirko za grče znašajo $\mu_r = 108,6$, $\mu_g = 83,4$, $\mu_b = 72,4$ za les pa $\mu_r = 162,4$, $\mu_g = 141,9$, $\mu_b = 119,7$. Povprečne vrednosti standardnega odklona intenzitete za celotno podatkovno zbirko za grče znašajo $\sigma_r = 20,6$, $\sigma_g = 19,2$, $\sigma_b = 15,1$ za les pa $\sigma_r = 14,8$, $\sigma_g = 17,2$, $\sigma_b = 15,77$.



(a) Porazdelitev povprečne intenzitete za grčo

(b) Porazdelitev povprečne intenzitete za les



(c) Porazdelitev standardnega odklona intenzitete za grčo

(d) Porazdelitev standardnega odklona intenzitete za les

različnih vrednotenjih zmogljivosti sistemov strojnega učenja. Več o tem lahko najdemo v delu [38, str. 163–180]. Osnovne merjene količine v matriki napak so:

- resnično pozitiven razred – število pravilno napovedanih primerov pozitivnega razreda – TP (angl., *true positive*),
- neresnično negativen razred – število napačno napovedanih primerov pozitivnega razreda – FN (angl., *false negative*),
- neresnično pozitiven razred – število napačno napovedanih primerov negativnega razreda – FP (angl., *false positive*),
- resnično negativen razred – število pravilno napovedanih primerov negativnega razreda – TN (angl., *true negative*).

Grafični prikaz teh količin si lahko bralec ogleda na Sliki 4.10. Podajmo še izpeljane veličine:

- točnost (angl., *accuracy*)

$$A = \frac{TP + TN}{TP + TN + FP + FN}, \quad (4.10)$$

- točnost, podana po izzivu Pascalove klasifikacije objektov [14, str. 314]

$$A_P = \frac{TP}{TP + FP + FN}, \quad (4.11)$$

- preciznost (angl., *precision*)


$$P = \frac{TP}{TP + FP}, \quad (4.12)$$

- priklic (angl., *recall*)

$$R = \frac{TP}{TP + FN}, \quad (4.13)$$

- F-mera (angl., *F-measure*)

$$F = \frac{2 \cdot R \cdot P}{R + P}. \quad (4.14)$$




Slika 4.10: Grafični prikaz vsebine matrike napak, podane v Tabeli 4.1. Z zeleno barvo je prikazan delež prepoznanih pozitivnih primerov, z rdečo pa delež prepoznanih negativnih. Iz slike lahko vidimo, da so nekateri pozitivni in negativni primeri pripisani napačnemu razredu.

Iz področja iskanja podatkov prihajata meri preciznost in priklic. Preciznost je delež pravilno razvrščenih pozitivnih primerov med vsemi napovedanimi pozitivnimi primeri. Govori o verjetnosti, da je naključno pridobljen podatek relevanten. Priklic podaja delež pravilno razvrščenih pozitivnih primerov med vsemi pozitivnimi primeri. Govori o verjetnosti, da je bil relevanten podatek dejansko najden.

Fazo vrednotenja uspešnosti predlagane metode smo izvedli večkrat pri različnih pogojih. Pri tem smo podano masko perturbirali za Δ slikovnih elementov v smereh x in y . Na Sliki 4.11 podajamo še grafični prikaz poteka vrednotenja.

4.5 Analiza metode Otsu

Najprej bomo predstavili rezultate, pridobljene na podlagi metode Otsu, ki nam bo služila kot osnovna mera uspešnosti pri vrednotenju metode *Knot-cut*. Na tej točki naj spomnimo, da je metoda primerna za segmentacijo bimodalnih porazdelitev. Segmentacijo barvne slike smo rešili tako, da smo vsak barvni kanal obravnavali ločeno, rezultate pa združili s pomočjo bitne operacije *in*. Na Sliki 4.12 lahko vidimo primer takšne segmentacije, kjer so optimalno izbrane pragovne vrednosti po metodi Otsu $T_r = 132$, $T_g = 112$ in




Slika 4.11: Grafični prikaz poteka vrednotenja predlagane metode za fino segmentacijo in lokalizacijo

$T_b = 100$. Grča je dobro ločena od ozadja, dobljeni rezultati segmentacije so: točnosti $A = 98,06\%$ in $A_P = 88,65\%$, preciznost $P = 0,87$, priklic $R = 1,00$ ter mera $F = 0,94$.

Pri obdelavi celotne zbirke grč smo dobili povprečni točnosti $\mu_A = 91,26\%$ in $\mu_{A_P} = 66,34\%$ pri povprečni preciznosti $\mu_P = 0,72$ in priklicu $\mu_R = 0,92$. Dobljena povprečna F -mera znaša $0,77$. V Tabeli 4.2 smo podali pridobljene povprečne vrednosti in standardne odklone. Opazimo lahko občutno razliko med povprečno točnostjo μ_A in μ_{A_P} . To lahko opazimo v veliki razpršenosti na grafičnem prikazu rezultatov za celotno podatkovno zbirko na Sliki 4.13. Iz enakega razloga kot v primeru točnosti lahko vidimo nizko povprečno vrednost preciznosti in visoko vrednost priklica. Podrobni pregled rezultatov nekaj izbranih primerov, ki jih podajamo v Tabelah 4.3 in 4.4, bo pokazal, da metoda zaide v težave, kadar osnovna predpostavka o bimodalnosti odpove.

Izbrane rezultate uspešnih primerov segmentacije grč po metodi Otsu, podane v Tabeli 4.3, lahko vidimo na Sliki 4.14. To so primeri, kjer je bila razlika med izračunanimi točnostma najmanjša, hkrati pa sta visoki vrednosti preciznosti in priklica. Posledično je visoka vrednost mere F . Prikaz deleža FP , podanega v zeleni barvi, in FN , podanega v rdeči barvi, je vidno zanemarljiv. Za primer grče na Sliki 4.14c smo podali histogramsko poraz-

Slika 4.12: Primer binarizacije Otsu za grčo pod zaporedno številko 14 z oznako ID000298. (a) Barvno sliko smo razbili na posamezni kanal (od leve proti desni si sledijo rdeč, zelen in moder), ki ji nato obravnavamo ločeno. (b) Optimalno izbrane pragovne vrednosti po metodi Otsu so $T_r = 132$, $T_g = 112$ in $T_b = 100$. Rezultat posameznih binarnih slik smo združili v skupno sliko s pomočjo bitne operacije *in*.




(a) Barvna dekompozicija

(b) Prag T pri 132, 112 in 100

Tabela 4.2: Rezultati segmentacije zbirke na podlagi metode Otsu. V tabeli so prikazane povprečne vrednosti μ in standardni odkloni σ za točnost A in A_P , preciznost P , priklic R in F -mero

	A	A_P	P	R	F
μ	91,26	66,34	0,72	0,92	0,77
σ	9,53	23,38	0,25	0,10	0,19



Slika 4.13: Grafični prikaz rezultatov segmentacije zbirke na podlagi metode Otsu. Zgornji graf prikazuje točnost A in A_P . Na abscisni osi so navedeni posamezni primeri, na ordinati pa izračunana vrednost. Spodnji graf prikazuje absolutno razliko med točnostjo A in A_P .

Tabela 4.3: Izbrani rezultati segmentacije zbirke na podlagi metode Otsu. Na Sliki 4.13 na spodnjem grafu so to primeri, ki imajo najmanjšo razliko med točnostjo A in točnostjo A_P . Te primere in njihove napake v segmentaciji lahko vidimo na Sliki 4.14.

ID	#	A	A_P	P	R	F
000132	5	99,66	97,49	0,99	0,98	0,99
000885	43	99,53	96,52	1,00	0,98	0,98
002578	94	99,22	94,72	0,97	0,98	0,97
003270	109	99,58	97,15	0,99	0,99	0,99

delitev, ki je na Sliki 4.16. Vidimo lahko, da je bimodalnost res prisotna.

V Tabeli 4.4 smo podali nekaj primerov, kjer je razlika med izračunanimi točnostma največja. Pri analizi preciznosti in priklica vidimo, da je prvi nizek, drugi pa visok. To pomeni, da smo med relevantnimi podatki dobili veliko FP . Na Sliki 4.15 je tako mogoče videti prisotnost FN kot regije, prikazane z zeleno barvo. Za primera št. 18 in št. 118 smo podali histogramski porazdelitvi na Slikah 4.17 in 4.18. Iz prikazanih porazdelitev lahko vidimo, da je bimodalnost v primerjavi s porazdelitvijo 4.14c manj izrazita ali celo premaknjena v desno na intenzitetni lestvici.

Kot zanimivost naj izpostavimo primer št. 18, ki ima priklic enak 1, kar pomeni, da je napaka FN enaka 0. Čeprav smo pravilno prepoznali vse slikovne elemente grče, je napaka, ki smo jo pri tem storili, tako velika, da rezultat nima praktične uporabne vrednosti. To se neposredno zrcali v rezultatu preciznosti, ki znaša približno 0,2.

Slika 4.14: Izbrani rezultati segmentacije zbirke na podlagi metode Otsu, prikazani v Tabeli 4.3. Sliki sta podani v paru: na prvi sliki je grča z označeno belo obrobo na podlagi ročno pridobljene maske; na drugi sliki je prikaz napake v segmentaciji. Z zeleno barvo je označena regija FP , z rdečo pa regija FN . ID000132 (#5) na Slikah (4.14a) in (4.14b); ID000885 (#43) na Slikah (4.14c) in (4.14d); ID002578 (#94) na Slikah (4.14e) in (4.14f); ID003270 (#109) na Slikah (4.14g) in (4.14h).





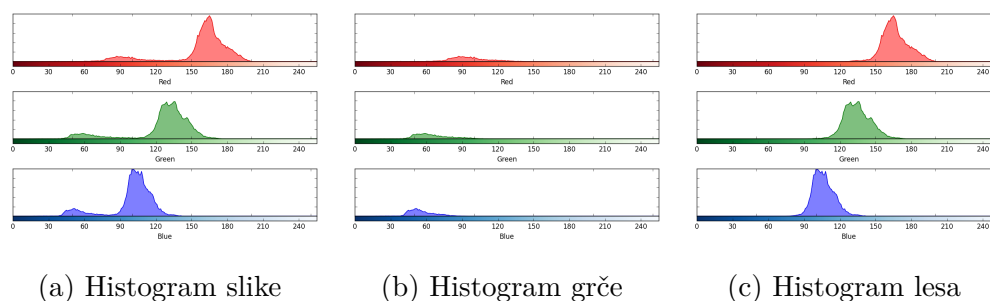
Tabela 4.4: Izbrani rezultati segmentacije zbirke na podlagi metode Otsu. Na Sliki 4.13 na spodnjem grafu so to primeri, ki imajo največjo razliko med točnostjo A in točnostjo A_P . Te primere ter njihove napake v segmentaciji lahko vidimo na Sliki 4.15.

ID	#	A	A_P	P	R	F
000368	18	78,95	20,85	0,21	1	0,35
001758	76	90,55	33,24	0,33	0,99	0,50
003476	112	83,82	20,86	0,21	0,97	0,35

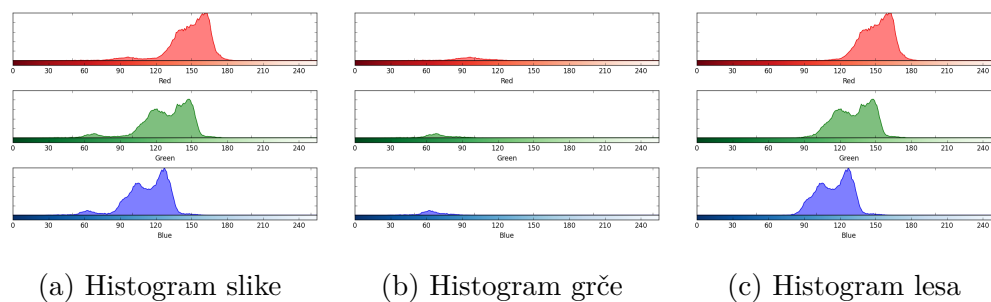
Slika 4.15: Izbrani rezultati segmentacije zbirke na podlagi metode Otsu prikazani v Tabeli 4.4. Sliki sta podani v paru: na prvi sliki je grča z označeno belo obrobo na podlagi ročno pridobljene maske; na drugi sliki je prikaz napake v segmentaciji. Z zeleno barvo je označena regija FP , z rdečo pa regija FN . ID000368 (#18) sliki (a) in (b); ID001758 (#76) sliki (c) in (d); ID003476 (#112) sliki (e) in (f).



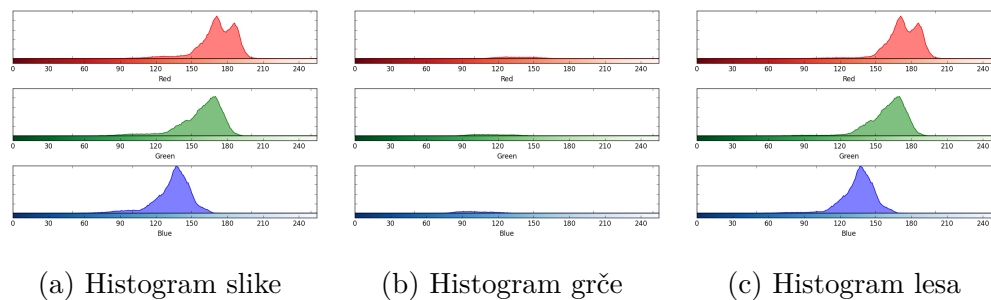
Slika 4.16: Primer porazdeljenosti slikovnih elementov za Sliko 4.14c, ki pripada primeru #43



Slika 4.17: Primer porazdeljenosti slikovnih elementov za Sliko 4.15a, ki pripada primeru #18



Slika 4.18: Primer porazdeljenosti slikovnih elementov za Sliko 4.15e, ki pripada primeru #112



Slika 4.19: Primer delovanja segmentacije Felzenszwalb [15]. (4.19a) Slika grče, nad katero smo izvedli segmentacijo. (4.19b), (4.19c), (4.19d) Rezultati metode pri različnih parametrih: Γ_σ – predprocesiranje slike z glajenjem pred segmentacijo, Γ_κ – parameter za kriterijsko funkcijo, Γ_{siz} – najmanjša velikost segmenta v slikovnih elementih, upoštevana v fazi po segmentaciji.



(a) Slika grče

(b) $\Gamma_\sigma = 0,5$, $\Gamma_\kappa = 100$, $\Gamma_{\text{siz}} = 300$ (c) $\Gamma_\sigma = 0,6$, $\Gamma_\kappa = 250$, $\Gamma_{\text{siz}} = 500$ (d) $\Gamma_\sigma = 0,6$, $\Gamma_\kappa = 250$, $\Gamma_{\text{siz}} = 5000$

4.6 Analiza metode za učinkovito segmentacijo slik na osnovi grafov

Naslednji primer, s katerim smo želeli primerjati metodo *Knotcut*, je segmentacija Felzenszwalb [15], podana v Poglavlju 2.4. Na Sliki 4.19 lahko vidimo delovanje metode na primeru grče pod zaporedno številko 14 z oznako ID000298 pri različnih vrednostih vhodnih parametrov Γ_σ , Γ_κ , Γ_{siz} , podanih v Poglavlju 2.4.

Na delovanje metode vplivata predvsem parametra Γ_κ in Γ_{siz} . Naša naloga je bila poiskati takšen nabor parametrov, ki bi uspešno ločili grčo in les. Preliminarni pregled manjšega nabora parametrov je nakazal na morebitne težave pri izbiri univerzalnih vrednosti za reševanja problema segmentacije grč in lesa. Da bi problem bolje razumeli, smo pričeli s kvalitativno oceno uspešnosti segmentacije. Za ta namen smo izdelali orodje, s katerim smo lahko hitro pregledali širši spekter možnih vrednosti parametrov Γ_κ in Γ_{siz} .



Slika 4.20: Prikaz interaktivnega pregleda vpliva različnih vrednosti parametrov na rezultat segmentacije po metodi za učinkovito segmentacijo slike na osnovi grafov. Programsko kodo, ki spremlja delo [15], smo priredili za lažje preliminarno vrednotenje uporabnosti metode.

Prikaz preprostega pripomočka za kvalitativno oceno podajamo na Sliki 4.20.

Težave pri izbiri parametrov so se pokazale na dva načina: ali je bila končna slika segmentirana na preveliko število regij ali je bila grča združena v večjo regijo, ki je pripadala predvsem lesu. Po uvodnem prizadevanju za pridobitev optimalnega nabora parametrov smo ugotovili, da brez posega v osnovno delovanje algoritma metoda ne bo primerna za reševanje našega problema. Vrednotenje metode Otsu je bilo smiselno, saj ta nima eksternih parametrov. Metoda na podlagi grafov pa že v osnovi predvideva izbiro ustreznih parametrov, da dobimo željeno segmentacijo. Ker smo za podano nalogo kvalitativno ugotovili, da ne obstajata univerzalna parametra Γ_κ in Γ_{siz} , ki bi v splošnem vsaj približno uspešno ločila grčo in les, smo vrednotenje te metode opustili.

Po uvodni kvalitativni analizi se tako nismo odločili za sistematično iskanje parametrov, ki bi minimizirali napako čez celotno podatkovno zbirko grč. Nekaj primerov uporabljenih parametrov, ki nazorneje orišejo težave, podajamo v Tabeli 4.5, pridobljene rezultate lahko vidimo na Sliki 4.21. Preizkus metode je bil uvodoma privlačen predvsem zaradi njene računske učinkovitosti $O(n \log n)$. Nadaljnje preiskovanje problema je pokazalo, da je metoda uporabna predvsem kot faza predprocesiranja, ki zmanjša velikostni razred

Tabela 4.5: Težave pri uporabi metode za učinkovito segmentacijo na osnovi grafov [15] smo želeli prikazati na enakih primerih grč, kot smo jih izpostavili pri analizi metode Otsu. V tabeli podajamo uporabljene parametre; pri vseh primerih smo uporabili $\sigma = 0,6$. Rezultate lahko vidimo na Sliki 4.21.

ID	#	k_1	$minsize_1$	k_2	$minsize_2$
000132	5	250	1000	200	3800
000885	43	250	1000	250	4000
002578	94	330	1000	250	2000
003270	109	280	1500	200	3000
000368	18	270	3000	400	3000
001758	76	560	2000	400	2500
003476	118	200	2400	270	2400

problema, ki ga rešujemo. Lastnost prevelike segmentiranosti regij, kot je prikazana na Slikah 4.21h, 4.21i, 4.21l in 4.21m, je zelo uporabna v primerih reševanja problema klasifikacije objektov. Takšen primer lahko najdemo v delu [25].

Slika 4.21: Prikaz rezultatov segmentacije za podatke, podane v Tabeli 4.5. Pri tem podpisan indeks pri zaporedni številki primera pomeni, ali gre za prvi ali drugi nabor parametrov.

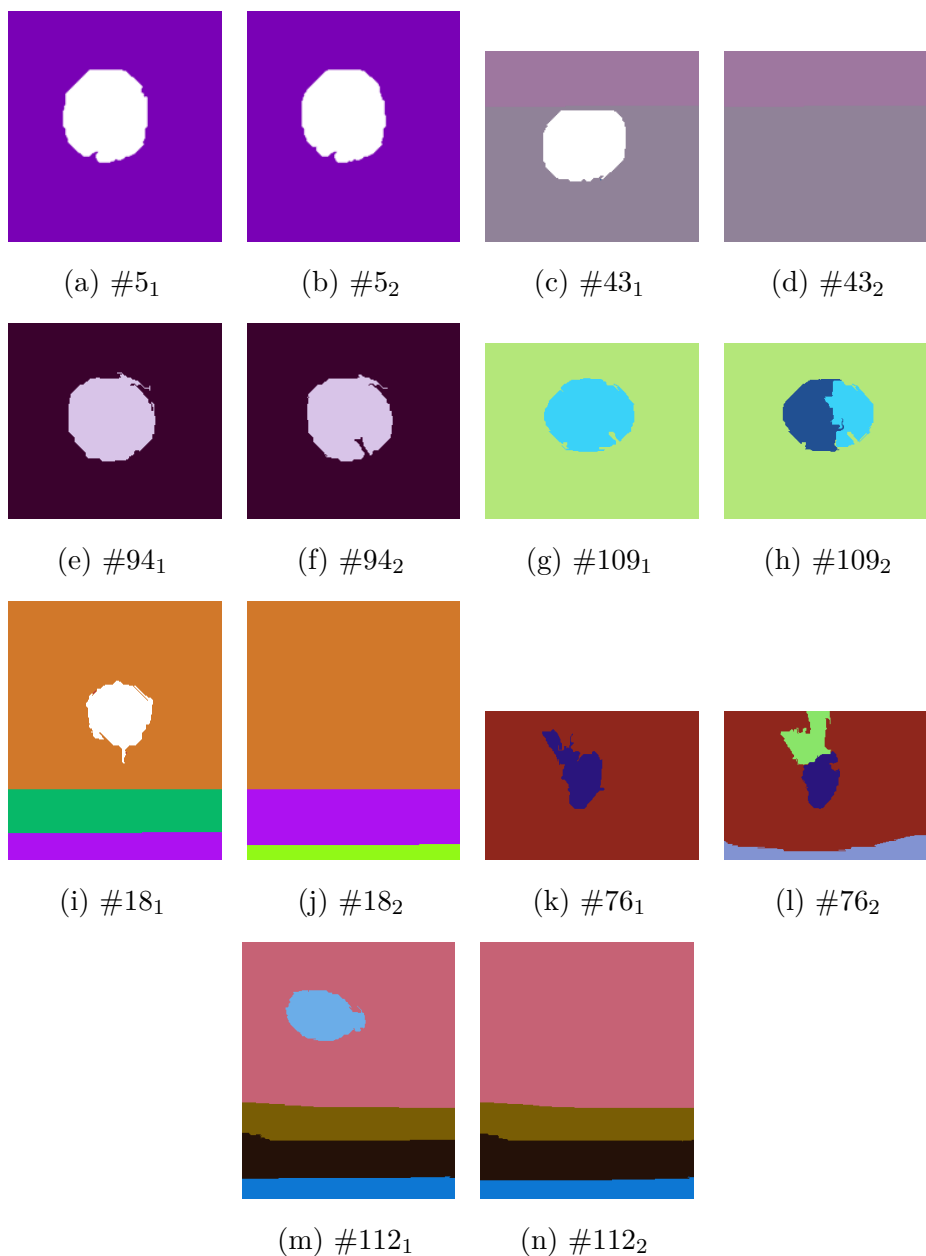


Tabela 4.6: Rezultati segmentacije zbirke na podlagi metode *Knotcut*. V tabeli so prikazane povprečne vrednosti μ in standardni odkloni σ za točnost A in A_P , preciznost P , priklic R in F -mero.


	A	A_P	P	R	F
μ	99,00	92,94	0,94	0,98	0,96
σ	1,25	8,81	0,08	0,05	0,05

4.7 Analiza predlagane metode

Sledijo rezultati, pridobljeni na podlagi predlagane metode *Knotcut*. Metoda je na celotni zbirki grč dosegla povprečni točnosti $\mu_A = 99,00\%$ in $\mu_{A_P} = 92,64\%$ pri povprečni preciznosti $\mu_P = 0,94$ in priklicu $\mu_R = 0,98$. Dobljena povprečna F -mera je znašala $\mu_F = 0,96$.

V nadaljevanju si bomo podrobneje ogledali nekaj izbranih primerov delovanja segmentacije *Knotcut*. Rezultate podajamo v Tabeli 4.7 ter Sliki 4.23. Primera številka 1 in 76 sta dva z največjo absolutno razliko med točnostjo A in A_P . Za primer številka 1 znašata točnosti $A = 93,56\%$ in $A_P = 58,81\%$, njuna razlika pa $|A - A_P| = 34,75\%$. Primeru številka 76 pripadata točnosti $A = 96,57\%$ in $A_P = 56,63\%$, njuna razlika je $|A - A_P| = 40,12\%$. Primera sta med sabo diametralno nasprotna. Prvi je imel nizek priklic, drugi pa nizko preciznost. Primer 1 ima nizek priklic zaradi velike napake pri napačno določenih slikovnih elementih lesa (FN – rdeča regija). Deloma izpadla grča in svetlejši odtenek na desni polovici sta povzročila, da je metoda ločnico predstavila na del, kjer se v resnici nahaja razpoka (Slika 4.23b). Drugi primer je imel nizko preciznost zaradi velike napake pri napačno določenih slikovnih elementih grče (FP – zelena regija). Vzrok se skriva v prenosu gnilobe na okoliški les (Slika 4.23d).

Izpostavili bomo še tri primere, ki so za nas nekaj posebnega. Primera številka 17 in 26 sta zanimiva zaradi deloma odrezanih grč. Naj ponovno spomnimo, da je zbirka grč pridobljena med proizvodnim procesom opažnih plošč, ki so zlepljene iz več, lahko tudi precej barvno raznolikih segmentov.



Slika 4.22: Rezultati segmentacije na podlagi metode *Knotcut*. Zgornji graf prikazuje točnost A in A_P . Na abscisni osi so navedeni posamezni primeri, na ordinati izračunana vrednost.

Tabela 4.7: Izbrani rezultati segmentacije zbirke na podlagi metode *Knotcut*. V tabeli so prikazane vrednosti za točnosti A in A_P , preciznost P , priklic R in F -mero.

ID	#	A	A_P	P	R	F
000011	1	93,56	58,81	1,00	0,59	0,74
000356	17	98,83	92,67	0,93	1,00	0,96
000506	26	99,85	98,92	0,99	1,00	0,99
001204	51	99,83	97,05	0,99	0,98	0,99
001758	76	96,57	56,63	0,59	0,94	0,72

Metoda je uspešno določila mejo takšne grče. Primer številka 17 ima točnost $A = 98,83\%$ pri preciznosti $P = 0,93$ in priklicu $R = 1,00$. Primer številka 26 ima točnost $A = 99,85\%$ pri preciznosti $P = 0,99$ in priklicu $R = 1,00$. Uspešnost segmentacije lahko vidimo na Slikah 4.23f in 4.23h. Pri primeru številka 51 lahko na Sliki 4.23i vidimo, da sta prisotni dve grči. Ob pridobivanju podatkovne zbirke je prišlo do napake in sta bili obe grči zaobjeti z enotno masko. Metoda *Knotcut* je kljub tako podani maski I_M uspešno ločila obe grči od preostalega dela lesa. Rezultati segmentacije so vidni na Sliki 4.23j.

4.7.1 Primerjava metod Otsu in Knotcut

Sedaj bomo predstavili primerjalno analizo metod Otsu in *Knotcut*. Metoda Otsu dosega naslednje povprečne vrednosti na celotni zbirki grč: točnosti $\mu_A = 91,26\%$ in $\mu_{A_P} = 66,34\%$, preciznost $\mu_P = 0,72$ in priklic $\mu_R = 0,92$, F -mera $\mu_F = 0,77$. Metoda *Knotcut* dosega naslednje povprečne vrednosti na celotni zbirki grč: točnosti $\mu_A = 99,00\%$ in $\mu_{A_P} = 92,64\%$, preciznost $\mu_P = 0,94$ in priklic $\mu_R = 0,98$, F -mera $\mu_F = 0,96$. Vse našteje povprečne vrednosti in standardne odklone za merjene veličine podajamo v Tabeli 4.8. Primerjava rezultatov metode *Knotcut* s tistima, pridobljenima po metodi Otsu, kaže na izboljšanje. To je predvsem opazno pri točnosti A_P in priklicu

Slika 4.23: Prikaz rezultatov segmentacije na podlagi metode *Knotcut*, podane v Tabeli 4.7. Sliki sta podani v paru: na prvi sliki je grča z označeno belo obrobo na podlagi ročno pridobljene maske ter svetlo modro elipso, ki predstavlja mejo vhodne maske I_M ; na drugi sliki je prikazana napaka, do katere je prišlo pri segmentaciji. Z zeleno barvo je označena regija FP , z rdečo pa regija FN .

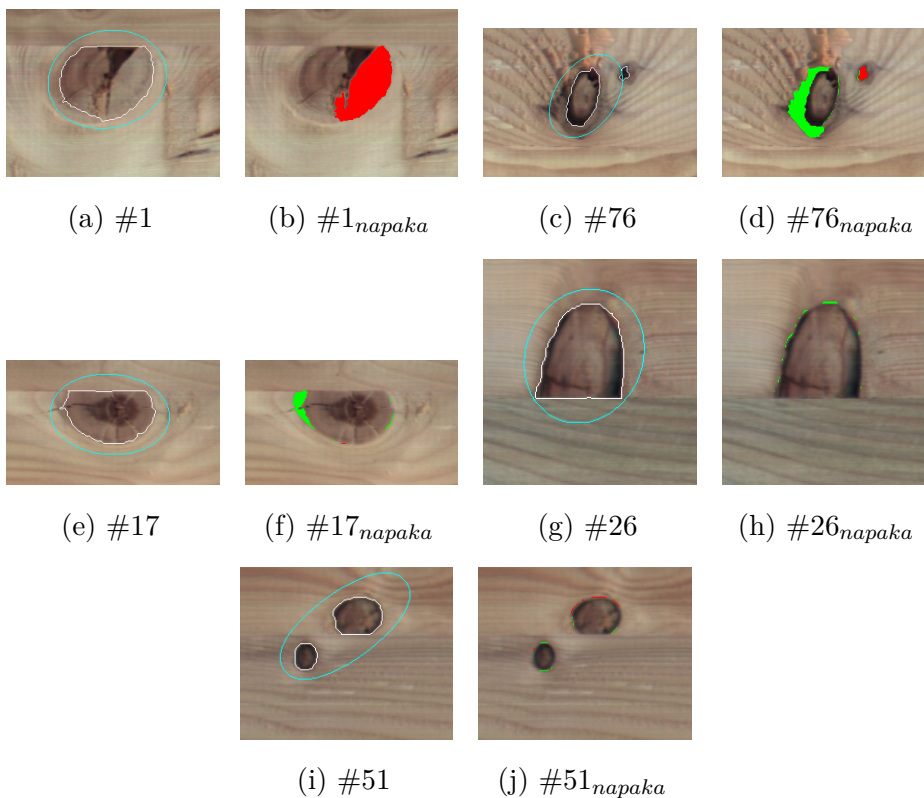


Tabela 4.8: Primerjava rezultatov segmentacije zbirke grč na podlagi metode Otsu (zgornja polovica) in predlagane metode *Knotcut* (spodnja polovica). V tabeli so prikazane povprečne vrednosti μ in standardni odkloni σ za točnost A in A_P , preciznost P , priklic R in mero F

	A	A_P	P	R	F
μ	91,26	66,34	0,72	0,92	0,77
σ	9,53	23,38	0,25	0,10	0,19
μ	99,00	92,94	0,94	0,98	0,96
σ	1,25	8,81	0,08	0,05	0,05

P . Enako lahko to razliko opazimo med grafi na Slikah 4.24a ter 4.24b, kjer je raztros točnosti pri metodi *Knotcut* občutno manjši, hkrati pa so manjši prikazi razlik $|A - A_P|$.

Primeri številka 18 in 112 sta zanimiva kot direktna primerjava uspešnosti segmentacije metode *Knotcut* v primerjavi z metodo Otsu. Za primer številka 18 se je točnost dvignila iz $A = 78,95\%$ na $A = 99,67\%$, za 112 pa iz $A = 83,82\%$ na $A = 99,89\%$. Preciznost se je v prvem primeru dvignila iz $P = 0,21$ na $P = 0,94$, v drugem pa iz $P = 0,21$ na $P = 0,98$. Vrednosti priklica sta bili že pred tem visoki. Posledično sta se seveda občutno izboljšali obe F -meri. Predstavljene rezultate podajamo v Tabeli 4.9, grafični prikaz napak pa na Sliki 4.25.

4.7.2 Analiza robustnosti metode *Knotcut*

Naposled smo preverili še, kako robustna je metoda *Knotcut*. S perturbiranjem vhodne maske I_M smo želeli preveriti, kako napačna preliminarne detekcije grč vpliva na uspešno fino segmentacijo in lokalizacijo. Vhodno masko I_M smo perturbirali za $\Delta \in \{0, \pm 5, \pm 10, \pm 20\}$ slikovnih elementov v smereh x in y . Prikaz izvedbe smo podali grafično na Sliki 4.11. Povprečne

Slika 4.24: Primerjava rezultatov segmentacije zbirke grč metod Otsu in *Knotcut*. Zgornji graf prikazuje točnost A in A_P . Na abscisni osi so navedeni posamezni primeri, na ordinati izračunana vrednost. Spodnji graf prikazuje absolutno razliko med A in A_P . Pri primerjavi grafov, podanih na Slikah 4.24a in 4.24b, lahko opazimo, da so točke, ki prikazujejo točnost A in A_P , manj razpršene (so se pomaknile višje na grafu). Hkrati lahko vidimo, da so daljice, ki ponazarjajo absolutno razliko med točnostjo A in A_P , mnogo krajše.

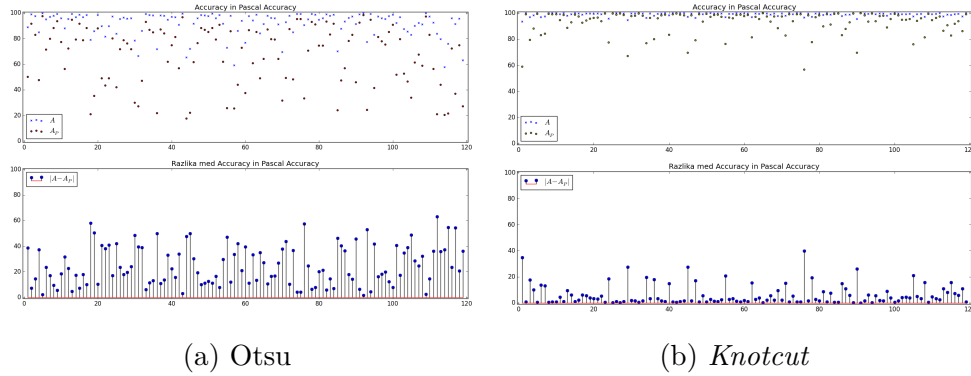



Tabela 4.9: Izbrani rezultati za primerjavo uspešnosti segmentacije zbirke med metodo Otsu (zgornja polovica) in metodo *Knotcut* (spodnja polovica). V tabeli so prikazane vrednosti za točnosti A in A_P , preciznost P , priklic R in F -mero.

ID	#	A	A_P	P	R	F
000368	18	78,95	20,85	0,21	1,00	0,35
003476	112	83,82	20,86	0,21	0,97	0,35
000368	18	99,67	94,26	0,94	1,00	0,97
003476	112	99,89	97,50	0,98	1,00	0,99

Slika 4.25: Prikaz primerjave rezultatov segmentacije izbranih primerov po metodah Otsu in *Knotcut*, ki ju podajamo v Tabeli 4.9. Sliki sta podani v paru: na prvi sliki je prikaz napake segmentacije metode Otsu, na drugi metode *Knotcut*. Z zeleno barvo je označena regija *FP*, z rdečo pa regija *FN*.



vrednosti perturbacije čez posamezen korak smo izračunali skladno z:

$$\overline{\mu}_\rho = \sum_{\varrho \in \Delta} \mu_{\rho, \varrho}. \quad (4.15)$$

Vrednosti za izhodiščno delto so: točnosti $\overline{\mu}_A = 99.00\%$ in $\overline{\mu}_{A_P} = 92.94\%$, preciznost $\overline{\mu}_P = 0.94$ in priklic $\overline{\mu}_R = 0.98$ ter *F*-mera $\overline{\mu}_F = 0.96$. Seveda so te enake podanim v Tabeli 4.6, saj maske v tem trenutku še nismo premaknili. Prvo večje odstopanje lahko zaznamo pri pomiku delte za plus ali minus 20 slikovnih elementov. Dobljene vrednosti znašajo: točnosti $\overline{\mu}_A = 97.5\%$ in $\overline{\mu}_{A_P} = 82.17\%$, preciznost $\overline{\mu}_P = 0.96$ in priklic $\overline{\mu}_R = 0.85$ ter *F*-mera $\overline{\mu}_F = 0.90$. Preostale rezultate smo podali v Tabeli 4.10.

Podroben pogled, na pridobljene rezultate perturbacije v Tabeli 4.11 in grafu na Sliki 4.26, nam potrdi, da so večje napake prisotne šele pri deltah, večjih od dvajset. Pri diagonalnih premikih smo v resnici masno središče maske premaknili za $\sqrt{2}\Delta$. Tako imamo na diagonalah premike velikost približno 7, 14 in 28 slikovnih elementov. Kot smo navedli v Poglavju 4.3, je bila izbira velikosti strukturnega elementa z radijem $r = 15,5$ slikovnih elementov izkustvena. Izbira vrednosti je bila pogojena z načinom uporabe maske I_M v metodi *Knotcut*. Spomnimo se, da slikovne elemente izven maske fiksiramo

Tabela 4.10: Rezultat povprečja povprečnih vrednosti izvedbe vrednote-nja vpliva napake, ob perturbaciji maske, na metodo *Knotcut* pri $\Delta \in \{0, \pm 5, \pm 10, \pm 20\}$. Povprečja smo izračunali čez posamezen razred koraka perturbacije Δ po (4.15).


Δ	$\overline{\mu_A}$	$\overline{\mu_{A_P}}$	$\overline{\mu_P}$	$\overline{\mu_R}$	$\overline{\mu_F}$
0	99,00	92,94	0,94	0,98	0,96
± 5	99,03	93,13	0,95	0,98	0,96
± 10	99,08	93,40	0,95	0,98	0,96
± 20	97,59	82,17	0,96	0,85	0,90

kot gotovo ozadje. Če usmerimo pozornost na povprečno vrednost točnosti μ_{A_P} v Tabeli 4.11 ali sliko pripadajočega grafa 4.26, lahko vidimo, da ta pade pri $\Delta = \pm 20$. Opazimo lahko, da je napaka še toliko večja pri diagonalnih premikih. To se sklada z ugotovitvijo, da smo masno središče maske pri tem v resnici premaknili za 28 slikovnih elementov. V obeh primerih smo naredili večji pomik, kot je bil radij uporabljenega strukturnega elementa.

Za konec podajmo še štiri izbrane primere napak pri segmentaciji, ki so posledica perturbacije vhodne maske I_M . Primera številka 22 in 78 imata tako nizke vrednosti točnosti A_P kot preciznosti P in priklica R . Za primer 22 te znašajo $A_P = 37,22\%$, $P = 0,63$ in $R = 0,47$, za primer 78 pa $A_P = 45,68\%$, $P = 0,52$ in $R = 0,78$. Čeprav znaša točnost $A = 88,59\%$ za prvi primer in $A = 90,39\%$ za drugi, je napaka prevelika, da bi imela kakršno koli uporabno vrednost. To seveda odražajo prav nizke vrednosti A_P , P in R . Segmentacije v primerih številka 55 in 105 je bila popolnoma neuspešna, saj nismo uspešno prepoznali niti enega dela grče. To se odraža v točnosti A_P , ki je kar enaka nič. Pričujoče rezultate smo podali v Tabeli 4.12 in na Sliki 4.27. V vseh štirih primerih lahko opazimo, da je premik maske I_M povzročil, da smo del grče napačno proglasili za ozadje (svetlo modra elipsa seka belo označen rob grče). Medtem ko je v primerih #22 in #78 grča še delno uspešno najdena, je v primerih #105 in #55 ta popolnoma zlita z ozadjem.

Tabela 4.11: Rezultati povprečnih vrednosti izvedbe vrednotenja vpliva napake, ob perturbaciji maske, na metodo *Knotcut*. Prikaz izvedbe smo podali grafično na Sliki 4.11; s črtkano črto smo ločili različne razrede pomikov, ki so znašali $\Delta \in \{0, \pm 5, \pm 10, \pm 20\}$.

Δ	μ_A	μ_{AP}	μ_P	μ_R	μ_F
(0, 0)	99,00	92,94	0,94	0,98	0,96
(5, 0)	99,10	93,51	0,95	0,98	0,96
(5, 5)	99,08	93,40	0,95	0,98	0,96
(0, 5)	98,98	92,89	0,94	0,98	0,96
(-5, 5)	98,95	92,71	0,94	0,98	0,96
(-5, 0)	98,93	92,55	0,94	0,98	0,96
(-5, -5)	98,98	92,79	0,95	0,98	0,96
(0, -5)	99,09	93,41	0,95	0,98	0,96
(5, -5)	99,14	93,78	0,95	0,98	0,97
(10, 0)	99,20	94,12	0,96	0,98	0,97
(10, 10)	99,20	94,02	0,96	0,98	0,97
(0, 10)	99,01	92,93	0,95	0,98	0,96
(-10, 10)	99,01	92,94	0,95	0,98	0,96
(-10, 0)	98,97	92,73	0,95	0,98	0,96
(-10, -10)	98,98	92,78	0,95	0,98	0,96
(0, -10)	99,08	93,35	0,95	0,98	0,96
(10, -10)	99,22	94,33	0,96	0,98	0,97
(20, 0)	98,63	90,02	0,97	0,92	0,95
(20, 20)	97,05	77,96	0,97	0,80	0,88
(0, 20)	98,69	90,57	0,97	0,94	0,95
(-20, 20)	96,42	73,91	0,96	0,77	0,84
(-20, 0)	98,50	88,91	0,96	0,93	0,94
(-20, -20)	96,41	73,48	0,96	0,76	0,84
(0, -20)	98,47	88,95	0,96	0,93	0,95
(20, -20)	96,51	73,57	0,96	0,76	0,85

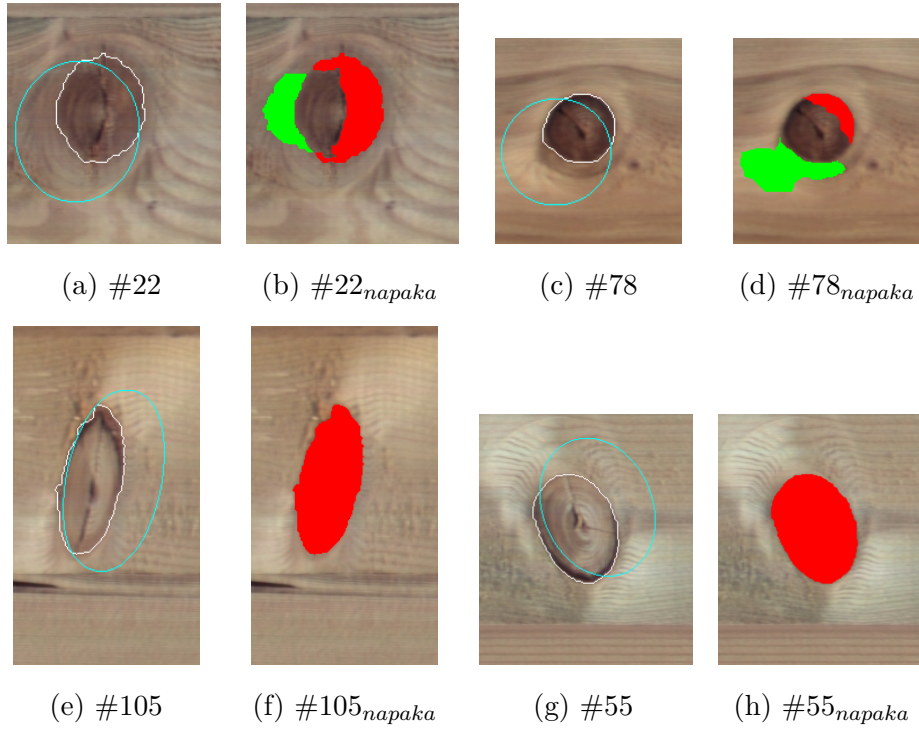


Slika 4.26: Prikaz točnosti A_P za izvedeno vrednotenja vpliva napake ob perturbaciji maske na metodo *Knotcut*

Tabela 4.12: Izbrani rezultati segmentacije zbirke po metodi *Knotcut* pri perturbiranju vhodne maske I_M za Δ slikovnih elementov. V tabeli so prikazane vrednosti za točnosti A in A_P , preciznost P , priklic R in F -mero.

ID	#	Δ	A	A_P	P	R	F
000470	22	$(-20, 20)$	88,59	37,22	0,63	0,47	0,54
001274	55	$(20, -20)$	87,01	0	/	0	/
001769	78	$(-20, 20)$	90,39	45,68	0,52	0,78	0,63
003118	105	$(20, 0)$	88,72	0	/	0	/

Slika 4.27: Prikaz izbranih rezultatov segmentacije metode *Knotcut* pri perturbiranju vhodne maske I_M za podatke, podane v Tabeli 4.12. Sliki sta podani v paru: na prvi sliki je grča z označeno belo obrobo na podlagi ročno pridobljene maske ter svetlo modro elipso, ki predstavlja mejo perturbirane maske I_M ; na drugi sliki je prikazana napaka, do katere je prišlo pri segmentaciji. Z zeleno barvo je označena regija FP , z rdečo pa regija FN .



Poglavje 5

Sklepne ugotovitve

V diplomskem delu smo obravnavali problematiko fine lokalizacije grč v procesu izdelave opažnih plošč. Predlagali smo metodo *Knotcut* za segmentacijo na podlagi iskanja najmanjšega prereza oziroma največjega pretoka v grafu. Metoda na podlagi grobo lokalizirane grče določi modela verjetnostne porazdelitve mešanice Gaussov za grčo in ozadje. Na podlagi pridobljenih modelov določimo območne in mejne uteži ter izgradimo graf, pri tem pa področje izven grobe regije grče upoštevamo kot seme in ga pripišemo ozadju. Izračun minimalnega prereza grafa je hkrati rešitev segmentacije. Rezultat sta dve ločeni regiji, kjer ena pripada grči, druga pa lesu.

Vrednotenje predlagane metode smo predstavili na zbirki 119 grč, pridobljeni pri enem izmed slovenskih proizvajalcev opažnih plošč med procesom izdelave. Uspešnost metode smo vrednotili na podlagi ročno pridobljenih mask, ki ločujejo grče in les. Mejo smo postavili subjektivno in s tem v vrednotenje vnesli nekaj pristranskosti. Problem se bistveno razlikuje od segmentacije npr. nogometne žoge na zelenici in ga je potrebno tako gledati v pravem kontekstu. Odločitve smo sprejemali na podlagi izkušenj, pridobljenih tekom dela v procesu avtomatizacije proizvodnje opažnih plošč.

Validacijo sistema smo zastavili v več korakih. Najprej smo želeli postaviti izhodiščne mere uspešnosti segmentacije. Prva metoda, s katero smo želeli osvetliti to kompleksnost, je bila metoda Otsu. Z njeno pomočjo smo se

prepričali, kako pomembna je pravilna izbira merjenih atributov, na podlagi katerih sprejemamo odločitve. Izmerjena točnost na zbirki grč je znašala 91,26% pri preciznosti 0,72 in priklicu 0,92. Hitro smo uvideli, da je potrebno predpostavke vedno preverjati. Čeprav se je v nekaterih primerih bimodalnost izkazala kot zadostna, je bila v praksi neuporabna.

Težavnost problema smo dodatno potrdili na primeru segmentacije na podlagi grafov. Interaktivno iskanje primerne nabora parametrov in kvalitativno ocenjevanje uspešnosti segmentacije sta pokazala, da ni vsaka metoda primerna za ločevanje grč od preostalega dela lesa. Napačen izbor parametrov hitro povzroči, da se regija grče zlije s svojo okolico.

Predlagana metoda *knotuct* daje vzpodbudne rezultate. Izmerjena točnost na zbirki grč je znašala 99,00% pri preciznosti 0,94 in priklicu 0,98. Tako lahko rečemo, da so rezultati segmentacije uporabni in hkrati dokaj popolni. Posledično lahko to vidimo v visoki vrednosti F -mere, ki znaša 0,96. Ustreznost metode *Knotcut* smo dodatno potrdili s predstavitevjo uspešne segmentacije na primerih, kjer je metoda Otsu odpovedala.

Ključni del vrednotenja smo opravili s perturbacijo vhodne maske I_M . Na uspešnost metode je odločilno vplivala izbira velikosti strukturnega elementa za morfološko operacijo širjenja. V trenutku, ko smo opravili premik, ki je bil nekaj večji kot radij strukturnega elementa, je maska presekala resnično mejo med grčo in lesom. Tako smo zmotno del grče pripisali lesu, kar je povzročilo večje napake v kvaliteti segmentacije. Izmerjena točnost na zbirki grč pri radiju $r = 15,5$ in pomiku $\Delta = \pm 20$ slikovnih elementov je znašala 97,59% pri preciznosti 0,96 in priklicu 0,85.

Če postavimo rezultate v širši kontekst proizvodnje opažnih plošč, lahko vidimo, da prihaja do napak dveh tipov. Drugi tip, popolnoma zgrešena grča, kjer je celotna grča napačno pripisana lesu, bi tekom proizvodnega cikla povzročil manj škode. Na tem mestu stroj za krpanje ne bi izvedel nobenega posega. Tako bi lahko v nadaljevanju proizvodnega procesa napako še uspešno popravili. Prvi tip, kjer je bila storjena dvojna napaka, tako v grči, ki je bila napačno pripisana lesu, kot v lesu, ki je bil napačno pripisan grči,

pa bi v resnici spremenil tako lokacijo kot velikost potrebne krpe. Napake takšnega tipa bi lahko bistveno vplivale na kakovost končnega izdelka.

Tehnološka dovršenost v slovenski lesnopredelovalni industriji ni nekaj povsem samoumevnega, obstaja pa zavedanje, da je za konkurenčnost panoge nujno potreben napredek. Rešitev za uspešnost podjetij v tekmi s poceni kitajsko in indijsko delovno silo je tehnološko posodabljanje proizvodnih obratov v celotni verigi. Naš prispevek je metoda *Knotcut*, ki se dotika dela procesa v proizvodnji opažnih plošč. Ozko grlo v procesu izdelave je fizično težko opravilo krpanja grč. Ena izmed ključnih komponent takšnega avtomatiziranega sistema je fina lokalizacija grč.

5.1 Nadaljnje delo

Glede na predstavljene rezultate se nam zdi smiselno delo v tej smeri nadaljevati. Da bi lahko dobljenim rezultatom bolje zaupali, bi bilo zbirko grč dobro povečati. Za oceno pristranskosti pri ročnem označevanju bi morali v to opravilo vključiti dodatne označevalce. Večjo težo našim podatkom bi lahko dali z vključitvijo strokovnjaka za lesarstvo z biotehniške fakultete.

V delu smo privzeli fiksno vrednost parametra λ , podanega v (2.2), ki določa razmerje med prispevkom območnega in mejnega dela. Boykov in Jolly v [7, str. 110] prikažeta vpliv tega parametra na rezultate segmentacije sintetičnega primera, definiranega na podlagi principov Gestalt. Smiselno bi bilo izbrati takšno vrednost λ , ki maksimizira preciznost in priklic nad celotnim naborom podatkov.

Izbira uporabe maske I_M in pri tem uporaba semen samo za ozadje se skriva v zelo grobi informaciji o potencialni velikosti grče. Zanimivo bi bilo preizkusiti različne oblike mask, hkrati pa spreminjati obliko in uporabo semen za fiksiranje grče, lesa ali obeh hkrati. Takšen pristop bi nam lahko v primerih napak, kot je prikazana na Sliki 4.23b, te odpravil.

Tekom celotnega dela smo se ukvarjali samo z informacijo, pridobljeno na podlagi barvnega zajema. V Poglavju 4.1 na Sliki 4.1 lahko vidimo pri-

sotne tudi druge modalitete. V našem primeru bi lahko metodo razširili in uporabili še podatke, pridobljene z zajemom na podlagi laserskega sipanja ter 3D–laserske triangulacije. Smiselno bi bilo sistematično vrednotenje zmogljivosti sistema z uporabo ene ali več različnih modalitet. Hkrati bi lahko raziskali, ali je mogoče na novo pridobljene informacije uporabiti za robustno določanje semen v postopku segmentacije. Videli smo namreč, da imajo lahko te ključno vlogo pri uspešnem ali napačnem rezultatu segmentacije.

Do sedaj se nismo posebej spraševali o učinkovitosti implementirane metode, razen v primeru obravnave različnih algoritmov za izračun največjega pretoka oziroma najmanjšega prereza v grafu. Zavedamo pa se, da še tako uspešna metoda ni uporabna, če v celoti ne izpolnjuje svojega poslanstva. V našem primeru je to optimizacija procesa izdelave opažnih plošč. V tem kontekstu bi bilo smiselno razviti ali uporabiti metode, ki to delo opravijo učinkovito. Kot primer naj navedemo različico vzporednega algoritma za učenje modela mešanice Gaussovih porazdelitev avtorjev Lenar in Žibert [24].

Literatura

- [1] WoodEye AB. WoodEye 5. [Ogled 26. 7. 2016]. Dostopno na <http://woodeye.se/en/woodeye-5/>.
- [2] M. Amadasun in R. A. King. Low-level Segmentation of Multispectral Images via Agglomerative Clustering of Uniform Neighbourhoods. *Pattern Recogn.*, 21(3):261–268, maj 1988.
- [3] Klemen Bedekovic in Irena Leban. Lesne plošče. [Ogled 9. 3. 2016]. Dostopno na http://www.cpi.si/files/cpi/userfiles/Lesarstvo_tapetnistvo/lesne_plosce.pdf.
- [4] Serge Beucher in Christian Lantuéjoul. Use of Watersheds in Contour Detection. workshop published, september 1979. Dostopno na <http://cmm.ensmp.fr/~beucher/publi/watershed.pdf>.
- [5] Christopher M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006.
- [6] Yuri Boykov in Gareth Funka-Lea. Graph Cuts and Efficient N-D Image Segmentation. *Int. J. Comput. Vision*, 70(2):109–131, november 2006.
- [7] Yuri Boykov in Marie-Pierre Jolly. Interactive Graph Cuts for Optimal Boundary and Region Segmentation of Objects in N-D Images. Objavljeno v *ICCV*, strani 105–112, 2001.

-
- [8] Yuri Boykov in Vladimir Kolmogorov. The maxflow-v3.01 library computes max-flow/min-cut on arbitrary graphs. [Ogled 26. 7. 2016]. Dostopno na <http://vision.csd.uwo.ca/code/>.
 - [9] Yuri Boykov in Vladimir Kolmogorov. An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Vision. *IEEE Trans. Pattern Anal. Mach. Intell.*, 26(9):1124–1137, september 2004.
 - [10] J Canny. A Computational Approach to Edge Detection. *IEEE Trans. Pattern Anal. Mach. Intell.*, 8(6):679–698, junij 1986.
 - [11] Chaipat Chunharas in Vilayanur S. Ramachandran. Out of the Shadows. *Scientific American MIND*, 27(4):57–61, julij/avgust 2016.
 - [12] P. Corke. *Robotics, Vision and Control: Fundamental Algorithms in MATLAB*. Springer Tracts in Advanced Robotics. Springer Berlin Heidelberg, 2011.
 - [13] Thomas H. Cormen, Charles E. Leiserson, Ronald L. Rivest, in Clifford Stein. *Introduction to Algorithms, Third Edition*. The MIT Press, 3rd edition, 2009.
 - [14] Mark Everingham, Luc Gool, Christopher K. Williams, John Winn, in Andrew Zisserman. The Pascal Visual Object Classes (VOC) Challenge. *Int. J. Comput. Vision*, 88(2):303–338, junij 2010.
 - [15] Pedro F. Felzenszwalb in Daniel P. Huttenlocher. Efficient Graph-Based Image Segmentation. *Int. J. Comput. Vision*, 59(2):167–181, september 2004.
 - [16] David A. Forsyth in Jean Ponce. *Computer Vision: A Modern Approach*. Pearson, 2011.

- [17] J.W. Funcka, Y. Zhongb, D.A. Butlerc, C.C. Brunnera, in J.B. Forrera. Image segmentation algorithms applied to wood defect detection. *Computers and Electronics in Agriculture*, 41:157–179, december 2003.
- [18] Andrew V. Goldberg. New Tricks for an Old Dog: Improved Max-Flow Algorithms. [Ogled 21. 2. 2015]. Dostopno na http://helper.ipam.ucla.edu/publications/gc2008/gc2008_7716.pdf.
- [19] Rafael C. Gonzalez in Richard E. Woods. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2008.
- [20] Gozdno gospodarstvo Postojna. Opažne plošče SLOPANEL. [Ogled 9. 3. 2016]. Dostopno na <http://www.ggp.si/sl/izdelki-in-storitve/opazne-plosce-slopanel>.
- [21] M. W. Hofmair, M. Melik-Merkumians, M. Böck, M. Merdan, G. Schitter, in A. Kugi. Patching process optimization in an agent-controlled timber mill. *Journal of Intelligent Manufacturing*, 2015.
- [22] Miha Humar, Nika Krajnc, Jože Kropivšek, Andreja Kutnar, Bernard Likar, Igor Miklaveč, Mitja Piškur, in Črtomir Tavzes. *Izhodišča za prestrukturiranje slovenske lesnopredelovalne industrije*. Biotehniška fakulteta, Oddelek za lesarstvo, sep 2012. [Ogled 10. 5. 2016]. Dostopno na http://www.mgrt.gov.si/fileadmin/mgrt.gov.si/pageuploads/DPK/CRPi_2010/Strategija_slovenske_lesne_industrije_2012.pdf.
- [23] Vladimir Kolmogorov in Ramin Zabih. What Energy Functions Can Be Minimized via Graph Cuts? Objavljeno v *Proceedings of the 7th European Conference on Computer Vision-Part III*, ECCV '02, strani 65–81, London, UK, UK, 2002. Springer-Verlag.
- [24] Jasna Lenar in Janez Žibert. Paralelizacija postopka za učenje modela mešanice Gaussovih porazdelitev. Objavljeno v *ERK*, strani 112–115, 2014.

-
- [25] Xi Li in Hichem Sahbi. Superpixel-based object class segmentation using conditional random fields. Objavljeno v *ICASSP*, strani 1101–1104. IEEE, 2011.
- [26] Fernand Meyer. Un algorithme optimal pour la ligne de partage des eaux. *Dans 8me congrès de reconnaissance des formes et intelligence artificielle*, 2(1):847–857, 1991.
- [27] Microtec. Goldeneye 500, Multi-Sensor Quality Scanner for lumber Grading, Chopping and Sorting for joinery and wood component manufacturers – doors, windows and wood furniture. [Ogled 26. 7. 2016]. Dostopno na <http://microtec.eu/assets/products/goldeneye-500/Microtec-Goldeneye-500-1.pdf>.
- [28] Microtec. Microtec. [Ogled 26. 7. 2016]. Dostopno na <http://microtec.eu/en/company/about/>.
- [29] S. Mohan in K. Venkatachalapathy. Wood Knot Classification using Bagging, maj 2012.
- [30] Nobuyuki Otsu. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1):62–66, 1979.
- [31] Carsten Rother, Vladimir Kolmogorov, in Andrew Blake. "GrabCut": Interactive Foreground Extraction Using Iterated Graph Cuts. *ACM Trans. Graph.*, 23(3):309–314, avgust 2004.
- [32] Robert Sedgewick in Kevin Wayne. *Algorithms (4th Edition)*. Addison-Wesley Professional, 2011.
- [33] Jianbo Shi in Jitendra Malik. Normalized Cuts and Image Segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.*, 22(8):888–905, avgust 2000.
- [34] Pawan Sinha. Once blind and now they see. *Scientific American*, 309(1):48–55, julij 2013.

-
- [35] Carsten Steger, Markus Ulrich, in Christian Wiedemann. *Machine Vision Algorithms and Applications*. Wiley-VCH, Weinheim, 2007.
- [36] Justin F. Talbot in Xiaoqian Xu. Implementing GrabCut. [Ogled 9. 3. 2016]. Dostopno na <http://research.justintalbot.org/papers/Grabcut.pdf>.
- [37] Emanuele Trucco in Alessandro Verri. *Introductory Techniques for 3-D Computer Vision*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 1998.
- [38] Ian H. Witten, Eibe Frank, in Mark A. Hall. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 3rd edition, 2011.
- [39] WoodEye. About us. [Ogled 26. 7. 2016]. Dostopno na <http://woodeye.se/en/about-us/>.
- [40] Irene Yu-Hua, Henrik Andersson, in Raul Vican. Wood defect classification based on image analysis and support vector machines. *Wood Science and Technology*, 44(4):693–704, 2010.
- [41] Ministrstvo za gospodarski razvoj in tehnologijo Republika Slovenija. Srečanje s predstavniki slovenske lesnopredelovalne industrije. [Ogled 22. 8. 2016]. Dostopno na http://www.mgrt.gov.si/si/medijsko_sredisce/novica/archive/2012/5/browse/5/article/11987/8269/.
- [42] Ministrstvo za gospodarstvo Republika Slovenija. Javni razpis za pridobitev sredstev Evropskega sklada za regionalni razvoj – ESRR, Razvojni centri slovenskega gospodarstva. [Ogled 22. 8. 2016]. Dostopno na http://www.mgrt.gov.si/fileadmin/mgrt.gov.si/pageuploads/DPK/razvojni_centri_razpis_100730.pdf.

- [43] Hongyuan Zhu, Fanman Meng, Jianfei Cai, in Shijian Lu. Beyond Pixels: A Comprehensive Survey from Bottom-up to Semantic Image Segmentation and Cosegmentation. *CoRR*, abs/1502.00717, 2015.